

"Made available under NASA sponsorship
in the interest of early and wide dis-
semination of Earth Resources Survey
Program information and without liability
for any use made thereof."

8.0-10257

CR-163369

(E80-10257) CLASSIFICATION OF MULTISPECTRAL
IMAGES ACCORDING TO CROSSWISE TEXTURAL
CHARACTERISTICS (Instituto de Pesquisas
Espaciais, Sao Jose) 87 p HC A05/MF A01

N80-30840

Unclas

CSCL 05B G3/43 00257

RECEIVED BY
NASA STI FACILITY
DATE: 6-25-80
DCAF NO. 002949
PROCESSED BY
☒ NASA STI FACILITY
☐ ESA - SDS ☐ AIAA



CONSELHO NACIONAL DE DESENVOLVIMENTO CIENTIFICO E TECNOLÓGICO

INSTITUTO DE PESQUISAS ESPACIAIS

1. Classificação INPE-COM.4/RPE C.D.U.: 681.3.01:621.385R		2. Período	4. Distribuição
3. Palavras Chaves (selecionadas pelo autor) CARACTERÍSTICAS DE TEXTURA MATRIZES DE COCORRÊNCIA EQUALIZAÇÃO DE HISTOGRAMA			interna <input type="checkbox"/> externa <input checked="" type="checkbox"/>
5. Relatório nº INPE-1734-RPE/134	6. Data Maio, 1980	7. Revisado por <i>Flavio R.D. Velasco</i>	
8. Título e Sub-Título CLASSIFICAÇÃO DE IMAGENS MULTIESPECTRAIS, ATRAVÉS DE CARACTERÍSTICAS DE TEXTURA		9. Autorizado por <i>Nelson de Jesus Parada</i> Diretor	
10. Setor DSE/DIN	Código	11. Nº de cópias 10	
12. Autoria Enivaldo F. do Ó Filho Nelson D. A. Mascarenhas Claudio R. Sonnemburg		14. Nº de páginas 86	
13. Assinatura Responsável <i>Enivaldo F. do Ó</i>		15. Preço	
16. Sumário/Notas Este trabalho consiste na implementação de programas no sistema IMAGE-100, do INPE, destinados à extração de características espectrais e de textura, posterior utilização na classificação de imagens multiespectrais de recursos naturais, obtidas pelo satélite LANDSAT.			
<p>Original photography may be purchased from EROS Data Center Sioux Falls, SD 57918</p>			
17. Observações			

INDICE

ABSTRACT	v
LISTA DE FIGURAS	vi
LISTA DE TABELAS	vii
<u>CAPÍTULO I - INTRODUÇÃO</u>	1
1.1 - Generalidades	1
1.2 - Objetivos	7
<u>CAPÍTULO II - TEXTURA</u>	9
2.1 - Textura visual	9
2.2 - Espectro de Potência de Fourier	10
2.3 - Estatísticas de diferenças de níveis de cinza	12
2.4 - Estatísticas de comprimentos de cadeias	13
<u>CAPÍTULO III - ESTATÍSTICAS DE OCORRÊNCIAS</u>	15
3.1 - Matrizes de coocorrência	15
3.2 - Equalização do histograma	19
3.3 - Características de textura	21
<u>CAPÍTULO IV - ESTUDO PRINCIPAL</u>	29
4.1 - Dados utilizados	29
4.2 - Processamento	29
4.3 - Resultados	31
4.4 - Conclusões	51

AGRADECIMENTOS	53
BIBLIOGRAFIA	54
APENDICE A - PROCEDIMENTOS DE CLASSIFICAÇÃO	A.1
APENDICE B - LISTA DOS PROGRAMAS	B.1

ABSTRACT

This report describes programs for the IMAGE-100 system of INPE, for extraction of spectral and textural characteristics, followed by classification of LANDSAT earth resources multispectral images.

LISTA DE FIGURAS

I.1 - Respostas espectrais típicas	4
I.2 - Sistema para classificação automática de imagens	6
III.1 - Imagem simples e matrizes de coocorrência corresponden tes	17
III.2 - Função de distribuição acumulada	20
IV.1 - Imagem LANDSAT do nordeste do Mato Grosso	30
IV.2 - Característica: ASM-M	33
IV.3 - Característica: XIDM-D	34
IV.4 - Característica: ENT-M	35
IV.5 - Característica: CORME-M	36
IV.6 - Característica: 7-M	37

LISTA DE TABELAS

IV.1 - Número de janelas classificadas corretamente, utilizando-se características individuais	40
IV.2 - Número de janelas classificadas corretamente, utilizando-se pares de características	41
IV.3 - Características chave: ASM-M	42
IV.4 - Características chave: VAR-M	43
IV.5 - Características chave: XIDM-M	44
IV.6 - Características chave: XIDM.D	45
IV.7 - Características chave: XIDM-F	46
IV.8 - Características chave: SUMVAR-M	46
IV.9 - Características chave: SUMENT-M	47
IV.10 - Características chave: ENT-M	47
IV.11 - Características chave: CORME-M	48
IV.12 - Conjunto de características	50

CAPÍTULO I

INTRODUÇÃO

1.1 - GENERALIDADES

O campo de processamento digital de imagens tem sido objeto de muita pesquisa nos últimos anos. Este fato está diretamente relacionado ao constante aperfeiçoamento dos computadores digitais, que a cada dia se tornam mais rápidos e com maior capacidade de memória principal. Isto tem tornado possível a realização em tempos, senão curtos, pelo menos aceitáveis de diversos tipos de operações sobre os dados de imagem. Entre os objetivos dessas operações pode-se citar:

- 1) Restauração: consiste na recuperação de uma imagem que tenha sido degradada por um processo qualquer (por exemplo, ruído).
- 2) Realce: através de diversas técnicas, procura-se melhorar a qualidade da imagem ou ressaltar determinados aspectos, a fim de facilitar a detecção de certas estruturas ou objetos, eliminando informação irrelevante.
- 3) Codificação: nesta área de atividades, procura-se desenvolver técnicas de representação de uma imagem, reduzindo o volume de dados a serem transmitidos ou armazenados.
- 4) Reconhecimento de Padrões: trata-se do problema da classificação de uma imagem ou subimagem, em uma das várias classes pré-especificadas

Talvez pelo fato de ser uma área de estudos bem recente, a maior parte das pesquisas realizadas se limitam à solução de problemas bem específicos, envolvendo certas classes particulares de imagens, e, são gradualmente, uma generalização de técnicas de processamento digital de imagens se forma (Rosenfeld, 1969).

Dentre as inúmeras aplicações do estudo de processamento de imagens, tem-se a destacar aquelas que utilizam imagens multiespectrais, obtidas através de sensores remotos a bordo de satélites ou aviões. Dentro dos respectivos campos, tem-se:

- 1) Geologia: identificação de tipos de terreno, exploração de minerais, localização de falhas, estudos de erosão.
- 2) Agricultura e Agronomia: identificação e planejamento de culturas, análise de prejuízos causados por incêndios, geadas e pragas, controle de desmatamento.
- 3) Ecologia: detecção e monitoramento de poluição, análise de qualidade de água.
- 4) Hidrologia e Hidrografia: monitoramento de cursos de rios, mapeamento da costa.
- 5) Geografia: planejamento rural e urbano, planejamento de estradas, pesquisa de recursos.
- 6) Cartografia: construção e revisão de mapas.

Pela importância e diversidade de aplicações, pode-se avaliar o impulso dado pelo desenvolvimento de técnicas de sensoriamento remoto à área de processamento digital de imagens. De fato, devido à grande quantidade de dados obtidos através desses sensores, tornou-se necessária uma utilização de meios automáticos para processar e analisar esta informação.

Uma imagem multiespectral contém na realidade várias imagens (canais) da mesma cena, onde cada canal contém a resposta, em termos de reflectância daquela região, a uma faixa estreita do espectro eletromagnético incidente sobre ela. Normalmente, são utilizados 4 canais (0.5-0.6, 0.6-0.7, 0.7-0.8, 0.8-1.1 μ m), correspondendo a faixas nas regiões de verde, vermelho, infravermelho próximo e intermediário. Assim, um ponto da imagem pode ser interpretado como um ponto no espa

ção espectral 4-dimensional, onde cada coordenada representa o nível de reflectância para a cor correspondente à região que ele representa.

A classificação automática de imagens multiespectrais baseia-se no fato de que cada material apresenta uma resposta espectral única. Isto é ilustrado na Figura I.1, onde se tem as respostas típicas da água, do solo e da vegetação. Desta forma, a informação dos quatro canais, em conjunto, é utilizada para tentar separar tipos distintos de materiais, de modo que materiais diferentes ocupem regiões distintas no espaço espectral 4-dimensional (assinaturas). Se as diversas classes são especificadas através de assinaturas ou através de densidades de probabilidade sobre o espaço espectral, então uma classe é atribuída a um ponto, se este pertence à assinatura correspondente àquela classe, ou se ela é a classe mais provável.

No primeiro caso, tem-se um procedimento determinístico que é o método utilizado, originalmente, pelo sistema IMAGE-100. A vantagem desse método é a possibilidade de treinamento e classificação poderem ser feitos para cada classe (tema), separadamente das demais. Embora seja possível minimizar a sobreposição de assinaturas, através de vários refinamentos na fase de treinamento, se acontecer de um ponto pertencer a mais de uma assinatura, o sistema se omitirá da classificação. No segundo caso (Classificação estatística pelo sistema MAXVER desenvolvido no INPE) este problema é superado, obtendo-se precisão bastante superior no processo.

A classificação, discutida acima, é em geral a mais utilizada, principalmente, em imagens multiespectrais. Ela é feita numa base de celsa de resolução, uma vez que cada ponto da imagem é classificado isoladamente, não sendo para isso considerada a vizinhança do mesmo.

Pode-se também fazer a classificação numa base de bloco de celas de resolução contíguas. Um exemplo seria o caso da identificação do tipo de cultura de um campo inteiro de plantação. A chave




Fig. I.1 - Respostas espectrais típicas

da classificação deste tipo é a definição de um conjunto de características significativas, que contenham a informação de interesse, contida no bloco. Obviamente este conjunto é muito dependente da aplicação que se tem em vista. Por exemplo, um bom conjunto de características, para fins de classificação de microfotografias de células do sangue, talvez não fosse viável para diagnóstico automático de radiografias do tórax, nem tampouco para reconhecimento do tipo de terreno de certa região. Porém, uma vez escolhido esse conjunto de características, pode-se utilizar uma das diversas técnicas de reconhecimento de padrões, para efetuar a classificação propriamente dita (categorização).

No presente trabalho, sô consideraremos a classificação feita numa base de bloco de celas de resolução contíguas (janela). Portanto, as etapas distintas, em que um sistema classificador desse tipo se divide, são:

- 1) Preprocessamento: nesta fase, a janela a ser classificada passa por uma ou várias operações, de modo a evidenciar determinadas características que serão usadas para representá-la, ou então, com a finalidade de tornar estas características, invariantes em relação à posição, orientação, etc.
- 2) Extração de características: consiste na realização de uma série de medidas sobre a janela preprocessada, com a finalidade de se obter um vetor de características (ou primitivas) único, que represente aquela janela. A finalidade desta etapa é a redução da complexidade do sistema, cujo desempenho vai depender de uma boa escolha das características a serem extraídas (estas devem caracterizar propriedades comuns a todos os membros de cada classe). Como já foi dito, esta é a parte mais dependente daquilo que o sistema se propõe a classificar.
- 3) Categorização: como resultado da segunda etapa, tem-se uma ênupla de números reais, representando a janela em questão. Esta ênupla pode ser imaginada como um ponto dentro do espaço n-dimensional. Tem-se, então, um problema típico da área de reconhecimento de padrões, onde existe um grande número de métodos

para o projeto de categorizador (Tou and Gonzales, 1974; Fukunaga, 1972; Meisel, 1972).

A Figura I.2 apresenta um sistema prático para classificação automática de imagens

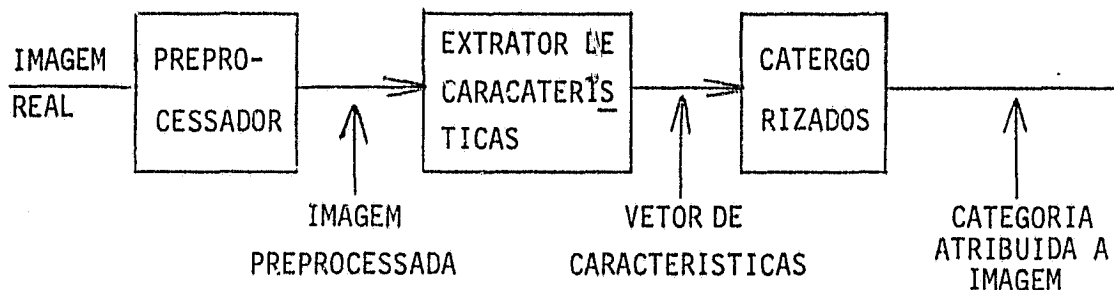


Fig.I.2 - Sistema para classificação automática de imagens.

Sendo uma imagem o objeto da classificação, é natural que se utilizem características similares às usadas pelo ser humano, na interpretação visual de uma fotografia. Para isto, ele utiliza três propriedades fundamentais: tonalidade, textura e contexto. Estas características sempre estão presentes numa imagem, embora eventualmente uma delas possa estar mais evidente. Da mesma forma, tem-se 3 tipos de características que podem ser utilizadas para efeito de classificação:

- espectrais: descrevem, em termos estatísticos, a distribuição dos níveis de cinza dos pontos do bloco considerado.
- textura: contém informação sobre a distribuição espacial das variações de níveis de cinza, dentro de um canal.
- contextuais: trazem informação derivada dos pontos ou blocos de imagem que estão mais próximos ao bloco que está sendo analisado.

É interessante notar que, embora seja fácil para um observador humano reconhecer e descrever, em termos empíricos, a textura, ela tem sido refratária a uma definição precisa e a uma análise exata por computadores digitais (Haralick et al., 1973 c).

No Capítulo II, tratar-se-á da textura e dos tipos mais comuns de técnicas utilizadas para medi-la.

1.2 - OBJETIVOS

Haralick et al., (1973 c) sugeriram uma série de medidas de textura, baseadas nas matrizes de coocorrência ou de dependência espacial de níveis de cinza. Os resultados encontrados mostraram a utilidade dessas características na classificação de microfotografias, de rochas e de tipos de terreno, em imagem multiespectrais de satélites e em fotografias aéreas.

Este trabalho consiste na implementação de programas no Image-100, visando a extração das características de textura, citadas, em conjunto com características espectrais, e subsequente utilização na classificação de tipos de terreno. A imagem utilizada foi uma do LANDSAT de nº 175152-123730-7, obtida na passagem do dia 1/6/75. Um mapa geológico foi considerado como a verdade terrestre, para efeito de análise de desempenho das características.

Foi desenvolvido também um programa para visualização, no terminal Tektronix, da capacidade de separação de duas classes quaisquer, utilizando uma determinada característica.

O computador utilizado foi um PDP 11/45, que é o controlador de processos do sistema IMAGE-100, com uma memória central de 48K. A linguagem usada em todos os programas foi FORTRAN-IV.

CAPÍTULO II

TEXTURA

2.1 - TEXTURA VISUAL

O mundo que nos cerca contém uma grande variedade de texturas. De fato, a textura é uma propriedade inerente a todas as superfícies. Pode-se qualificá-la como sendo fina, grossa, irregular, lisa, linear e mais um sem número de adjetivos.

Embora todos tenham noção do significado de textura, é muito difícil defini-la em termos científicos precisos. Pickett (1970) observa que, para um padrão visual ser visto como uma textura, ele deve ter as seguintes características:

- 1) um grande número de elementos (variações espaciais em intensidade ou comprimentos de onda);
- 2) os elementos e as regras de espaçamento ou arranjo podem ser arbitrariamente manipulados, desde que uma característica de repetitividade ainda continue;
- 3) desde que haja suficiente detalhe em um pequeno ângulo de visão, uma textura característica desponta, mesmo quando os elementos básicos ou os espaçamentos são aleatoriamente distribuídos.

Vê-se que os atributos básicos de uma textura visual são *muitas e repetitivas variações*

Não é ainda bem conhecida a maneira pela qual o ser humano detecta e analisa informação textural, no processo de percepção visual de uma cena. Julesz (1965 e 1975) considera que existem dois níveis distintos de percepção visual de textura. Um espontâneo ou impressionista, caracterizado por uma percepção pura e outro deliberado, que exige a utilização de processo cognitivos para ser completa a percepção.

cepção. Trabalhando com imagens artificiais obtidas por computador, ele investiga a importância da textura na percepção visual humana e analisa as diversas limitações dessa percepção.

Também na aplicação específica em imagens, não se encontra um método perfeito de análise de textura. Sabe-se, entretanto, que ela desempenha papel importante, na detecção e no reconhecimento de objetos (Pickett, 1970), e na discriminação de tipos diferentes (Haralick et al., 1973 c e Haralick e Bosley, 1973 a). Hawkins (1970) mostra as dificuldades existentes no trabalho de extração de informação textual e conclui que a classificação de texturas é uma das mais difíceis tarefas, no campo de processamento de imagens.

A textura pode ser analisada em dois níveis: o estatístico e o estrutural. Do ponto de vista estatístico, a textura é definida através de um conjunto de parâmetros estatísticos, obtidos de um grande número de medidas locais, feitas na imagem. Do ponto de vista estrutural, tenta-se localizar elementos que ocorrem repetidamente e descobrir as regras de organização dos mesmos, dentro de determinadas subáreas da imagem. Quando se trabalha com imagens naturais, geralmente se utiliza o método estatístico, pois o estrutural é mais complicado.

A seguir serão mostradas algumas das técnicas mais comuns, usadas para fins de classificação de imagens, no sentido considerado neste trabalho, que é o de discriminação de blocos de células de resolução, em categorias preespecificadas.

2.2 - ESPECTRO E POTÊNCIA DE FOURIER

A transformada de Fourier, de uma imagem $f(x,y)$, é definida como:

$$F(u,v) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} e^{-2\pi j (ux + vy)} f(x,y) dx dy$$

O valor da potência num ponto (u,v) é:

$$|F(u,v)|^2 = F(u,v) \cdot F^*(u,v)$$

As características de textura, baseadas em medidas do espectro de potência de Fourier, utilizam dois fatos:

- 1) A distribuição radial (no espaço transformado) dos valores de potência está relacionada à rugosidade da textura. Enquanto uma textura grossa tem valores altos de potência perto da origem, numa textura fina, os valores de potência são mais espalhados.
- 2) A distribuição angular dos valores de potência está relacionada à direcionalidade (existência de bordas e linhas numa certa direção) da textura. Uma textura orientada numa direção θ terá valores altos de potência, concentrados perto da perpendicular a esta direção.

Estes fatos sugerem que sejam usadas características de textura, que sejam relacionadas às médias da potência, ao longo de anéis centrados na origem (para análise de rugosidade) e ao longo de cunhas (para análise de direcionalidade)

A transformada discreta de Fourier, de uma imagem digital de $N \times N$ pontos, é:

$$F(u,v) = \frac{1}{N^2} \sum_{m=0}^{N-1} \sum_{n=0}^{N-1} f(m,n) e^{2\pi j (mu + nv)},$$

$$0 \leq u,v \leq N-1$$

Tem-se, então, dois tipos padrões de medida de textura, baseados no espectro de potência:

$$\Phi_{r_1, r_2} = \sum_{r_1^2 < u^2 + v^2 < r_2^2} |F(u,v)|^2, \quad r_1 \text{ e } r_2 \text{ arbitrários.}$$

$$\Phi_{\theta_1, \theta_2} = \sum_{\theta_1 \leq \tan^{-1}(v/u) < \theta_2} |F(u,v)|^2, \quad \theta_1 \text{ e } \theta_2 \text{ arbitrários.}$$

Pode-se também fazer uma combinação desses tipos, o que corresponderia a calcular o somatório dos valores de potência, na interseção de anéis e cunhas.

Pelo fato de, em geral, a imagem não ser periódica, sendo seus lados opostos descontínuos, aparece uma direcionalidade adicional na horizontal e na vertical, que não deve ser levada em conta.

2.3 - ESTATÍSTICAS DE DIFERENÇA DE NÍVEIS DE CINZA

Considere-se uma imagem digital $f(m,n)$ quantizada em N níveis de cinza. Para um deslocamento arbitrário $d = (\Delta m, \Delta n)$, onde Δm e Δn são inteiros, é computado um vetor N -dimensional p_d , da seguinte forma: sua i -ésima componente $p_d(i)$ é o número de pares de pontos da imagem separados de d , tendo uma diferença de níveis de cinza igual a i . Se este vetor for normalizado, $p_d(i)$ fornece uma estimativa da probabilidade de que $f_d(m,n) = |f(m,n) - f(m + \Delta m, n + \Delta n)|$ assumo o valor i .

Observe-se que, para uma textura grossa e d pequeno, comparado ao tamanho do elemento de textura, é esperado que os pares de pontos separados de d tenham, normalmente, níveis de cinza próximos, de modo que $p_d(i)$ assume valores altos para i 's baixos. Da mesma forma, se a textura for fina e d for comparável ao tamanho do elemento, então, espera-se uma melhor distribuição dos valores das componentes de p_d .

Medindo-se o grau de espalhamento dos valores em p_d para vários d 's pode-se, então, ter uma medida da rugosidade da textura. Tem-se por exemplo, as características:

$$\text{- Contraste: } \text{CON} = \sum_{i=1}^{N-1} i^2 \cdot p_d(i)$$

$$\text{- Média : } \text{MED} = \frac{1}{N} \sum_{i=1}^{N-1} i \cdot p_d(i)$$

Além dessas características, pode-se obter informação adicional sobre a direcionalidade da textura, quando se comparam os diversos graus de espalhamento de p_d à medida que a direção de d é variada e sua magnitude é mantida constante.

Outro conjunto de característica deste tipo pode ser obtido através de vetores p_d extraídos, não a partir de pares de pontos isolados, mas fazendo-se uma média de níveis de cinza sobre um grupo de pontos vizinhos.

2.4 - ESTATÍSTICAS DE COMPRIMENTOS DE CADEIAS

Dividem-se os N níveis de cinza em M faixas distintas. Uma matriz \bar{e} , então, obtida de modo que seu elemento $p(i,j)$ seja o número de cadeias de comprimento j , em uma direção θ , consistindo de pontos, cujos níveis de cinza estejam dentro da i -ésima faixa.

É bem intuitivo o significado dessas cadeias: se uma textura é grossa, espera-se encontrar cadeias longas, ao passo que se a textura for fina, as cadeias serão mais curtas.

Utilizando-se parâmetros convenientes dessa matriz (por exemplo, um que dependa fortemente do número de cadeias longas), é possível obter medidas do tipo de textura da imagem. A direcionalidade pode ser medida através do levantamento de várias dessas matrizes, uma para cada direção θ das cadeias.

Como este tipo de medidas é muito dependente de ruído, pode-se fazer um préprocessamento, que consiste em um alisamento da imagem, de modo a minimizar esta influência.

CAPÍTULO III

ESTATÍSTICAS DE OCORRÊNCIAS

No segundo capítulo foram citados dois tipos de medidas de textura, baseadas em estatísticas de propriedades locais. Num, estas propriedades eram diferenças de níveis de cinza e no outro, comprimento de cadeias.

Neste capítulo, é mostrado com mais detalhes um terceiro tipo de estatísticas proposto por Haralick (1973 c), baseado nas matrizes de dependência espacial de níveis de cinza, ou matrizes de co-ocorrência. Assume-se que toda a informação de textura, existente, pode ser convenientemente representada (ou codificada) por um conjunto de matrizes computadas, para várias direções e distâncias entre pares de celas de resolução da imagem.

3.1 - MATRIZES DE COOCORRÊNCIA

Suponha-se que a imagem digital em análise, com N níveis de cinza, seja retangular e constituída de N_x celas de resolução na direção horizontal e N_y celas de resolução na direção vertical. Uma tal imagem será denominada janela. Aqui, não se considera pontos, mas celas de resolução, porque pode-se também trabalhar com vizinhanças de pontos elementares, e portanto, com níveis de cinza médios nestas vizinhanças. Sejam:

$L_x = \{1, 2, \dots, N_x\}$... domínio espacial horizontal

$L_y = \{1, 2, \dots, N_y\}$... domínio espacial vertical

$G = 1, 2, \dots, N$... conjunto dos níveis de cinza possíveis.

$L_y \times L_x$... conjunto de todas as celas de resolução da janela.

Nesta notação, a imagem seria uma função I , que associa a cada cela de resolução, algum nível de cinza, isto é, $I: L_x \times L_y \rightarrow G$.

Cada matriz é construída de modo que, para uma direção θ e uma distância especificada d , seu elemento $P(i,j)$ seja a frequência de ocorrência na janela de pares de resolução distanciados de d , numa posição a θ^0 , uma com nível de cinza i e a outra com nível de cinza j .

São usadas direções θ iguais a 0^0 , 45^0 , 90^0 e 135^0 . Definindo formalmente cada matriz, tem-se:

$$P(i,j,d,0^0) = \# \{((k,l),(m,n)) \in (L_y \times L_x) \times (L_y \times L_x) \mid k-m=0, |l-n|=d, \\ I(k,l) = i, I(m,n) = j\}$$

$$P(i,j,d,90^0) = \# \{((k,l),(m,n)) \in (L_y \times L_x) \times (L_y \times L_x) \mid |k-m|=d, l-n=0, \\ I(k,l) = i, I(m,n) = j\}$$

$$P(i,j,d,45^0) = \# \{((k,l),(m,n)) \in (L_y \times L_x) \times (L_y \times L_x) \mid (k-m=d, l-n=-d) \\ \text{ou } (k-m=-d, l-n=d), I(k,l) = i, I(m,n) = j\}$$

$$P(i,j,d,135^0) = \# \{((k,l),(m,n)) \in (L_y \times L_x) \times (L_y \times L_x) \mid (k-m=d, l-n=d) \\ \text{ou } (k-m=-d, l-n=-d), I(k,l)=i, I(m,n) = j\}$$

onde $\#$ significa o número de elementos do conjunto.

Na realidade, como se pode ver das definições das matrizes, o conceito de distância, utilizado, não foi euclidiano:

$$\text{dist}((k,l),(m,n)) = \max\{|k-m|, |l-n|\}$$

Pode-se também observar que essas matrizes são simétricas, isto é, $P(i,j,d,\theta) = P(j,i,d,\theta)$.

A Figura III.1 mostra uma imagem simples 4 x 4, com 3 níveis, e as matrizes correspondentes no caso da distância ser unitária.

1 1 2 3	$P_0 = \begin{bmatrix} 4 & 3 & 1 \\ 3 & 4 & 3 \\ 1 & 3 & 2 \end{bmatrix}$	$P_{45} = \begin{bmatrix} 2 & 1 & 1 \\ 1 & 4 & 3 \\ 1 & 3 & 2 \end{bmatrix}$
1 2 3 3		
2 2 2 3		
3 1 1 2		
	$P_{90} = \begin{bmatrix} 2 & 4 & 0 \\ 4 & 2 & 3 \\ 0 & 3 & 4 \end{bmatrix}$	$P_{135} = \begin{bmatrix} 0 & 4 & 1 \\ 4 & 4 & 1 \\ 1 & 1 & 2 \end{bmatrix}$

Fig. III.1 - Imagem simples e matrizes de coocorrência correspondentes.

Na determinação, por exemplo, do elemento (3,2) da matriz horizontal ($\theta = 0^\circ$), conta-se o número de pares de células adjacentes, horizontalmente, tal que a primeira tenha nível 3 e a segunda nível 2.

Devido à definição das matrizes, nota-se que cada par de células contíguas é contado duas vezes. A primeira no levantamento da entrada (i,j) da matriz, e a segunda no da entrada (j,i), onde i e j são os níveis de cinza das duas células.

Pode-se fazer uma normalização de cada uma dessas matrizes, de modo que a soma de todos os seus elementos unitária. Para isto é necessário o cálculo do número R de células de resolução vizinhas (de acordo com θ e d). No caso de distância 1, tem-se:

$\theta = 0^\circ$: para cada linha existem $2(N_x - 1)$ pares de células vizinhas. Como existem N_y linhas, há um total de $R_H = 2N_y (N_x - 1)$

$\theta = 90^\circ$: analogamente, $R_V = 2N_x (N_y - 1)$

$\theta = 45^\circ$: para cada linha, à exceção da primeira, existem $2(N_x - 1)$ pares de células vizinhas. Então $R_D = 2(N_x - 1)(N_y - 1)$

$\theta = 135^\circ$: analogamente, $R_E = 2(N_y - 1)(N_x - 1)$

Para uma distância d qualquer, obviamente menor que N_x e N_y , tem-se:

$$R_H = 2N_y(N_x - d)$$

$$R_D = 2(N_x - d)(N_y - d)$$

$$R_V = 2N_x(N_y - d)$$

$$R_E = 2(N_x - d)(N_y - d)$$

Após a normalização, pode-se encarar um certo elemento $P(i,j)$ de cada matriz, como sendo uma estimativa da probabilidade de que um dado par de células de resolução, satisfazendo a relação espacial para a qual a matriz foi computada, tenha níveis de cinza i e j . Embora a normalização não traga informação adicional sobre a textura da imagem, uma vez que os elementos $p(i,j)$ são iguais aos $P(i,j)$ da matriz não normalizada, a menos que uma constante multiplicativa adequada, ela se apresenta muito útil em dois aspectos:

- 1) aspecto computacional: após a extração das matrizes, é feito um intenso processamento, visando a obtenção de características de textura. Algumas operações envolvidas podem levar a uma ultrapassagem da capacidade de representação de números reais no computador. Isto ocorre, principalmente, quando a janela é constituída de muitas células de resolução:
- 2) de certa forma a normalização torna as características independentes das dimensões da janela que representam, dependendo apenas do tipo de textura contida. Ou seja, duas janelas com texturas idênticas, uma estando contida na outra, forneceriam as mesmas características. Isto, entretanto, ocorre dentro de certos limites, pois se a janela menor for muito pequena, ela po

de não conter informação de textura suficiente, de modo que seria mal caracterizada.

A esta altura é interessante citar dois aspectos relacionados à obtenção das matrizes de coocorrência. O primeiro é o fato de que o número de operações necessárias, para processar uma janela, é diretamente proporcional ao número n de celas de resolução existentes. Em comparação, para se obter transformadas de Fourier ou Hadamard, para fins de medida de textura, este número seria proporcional a $n \cdot \log n$. O segundo aspecto é que só há necessidade de trazer, à memória do computador, duas linhas da janela ao mesmo tempo, não havendo, portanto, forte exigência de armazenamento neste tipo de processamento.

3.2 - A EQUALIZAÇÃO DO HISTOGRAMA

No processo de digitalização da imagem, cada valor do grau de cinza é quantizado sobre uma faixa finita de níveis possíveis. Em consequência, pode ser computado um histograma de níveis de cinza que, a menos de uma constante, seria uma estimativa da função densidade de probabilidade da variável nível de cinza para aquela imagem.

A equalização do histograma consiste num processo após o qual, todos os níveis de cinza, da imagem transformada, apresentam a mesma frequência de ocorrência.

Embora a textura e a tonalidade sejam duas propriedades de que se interrelacionam, é natural e desejável que duas imagens de uma mesma cena, uma com níveis de cinza iguais aos da outra, a menos de uma constante aditiva (o que equivale a um histograma deslocado), forneçam características de textura iguais. A equalização do histograma garante que duas imagens, uma sendo transformação monotônica da outra, fornecem os mesmos resultados (Haralick et al., 1973 c).

Na prática, esta transformação monotônica pode ser devida a diferenças de iluminação, revelação, filmes, lentes ou digitalizador.

Além disso, a equalização permite que se fixe o número de níveis de cinza com que se está interessado em trabalhar. Isto é importante, devido à necessidade de armazenamento das matrizes. Existindo N níveis de cinza, é necessário o uso de N^2 palavras reais de memória para cada matriz (ou $N(N+1)/2$, no caso de se utilizar a propriedade de simetria). Acontece que a maioria das imagens apresentam um histograma concentrado numa faixa estreita de níveis de cinza. Aqui, não se tratando de acentuar ou melhorar visualmente o contraste, pode-se simplesmente trabalhar com um número de níveis aceitável pelo computador e compatível com esta faixa estreita do histograma.

No caso específico deste trabalho, a equalização admite que a imagem tenha no máximo 256 níveis (resolução máxima do sistema I-100), transformando-se em 32 níveis equalizados. O mecanismo é similar ao uso na transformação de distribuições em Estatística.

Seja o histograma da imagem no canal, em que a textura vai ser utilizada para efeito de classificação $A(i)$, $i=0,255$. A partir dele, obtém-se a função de distribuição acumulada dos níveis de cinza, conforme a Figura III.2.




Fig. III.2 - Função de distribuição acumulada

Então, é gerada uma tabela, relacionando os níveis, na imagem original, aos correspondentes após a equalização, de modo que se

$$\left(\frac{k-1}{32}\right) \leq \frac{\sum_{j=0}^i A(j)}{NT} \leq \left(\frac{k}{32}\right) \quad (1)$$

então, ao nível i será assinalado o nível k .

Pelo fato da distribuição ser discreta, aparecem problemas nas transações entre níveis da imagem transformada, quando então um certo nível, na imagem original, teria que ser designado para dois níveis diferentes. Isto seria resolvido com o uso, na fase de equalização propriamente dita, de uma sub-rotina, de números aleatórios de modo a se "rachar" um certo nível em dois outros, fornecendo uma equalização mais refinada. Como isto, forçosamente, demandaria um tempo considerável, resolveu-se fazer, simplesmente, uma escolha pela melhor colocação daquele nível original em um dos dois níveis transformados, não sendo portando, a equação (1) seguida à risca.

Seria interessante citar que, pelo menos na imagem utilizada, normalmente uma janela de 62 x 62 pontos não apresenta mais que 40 níveis de cinza, com frequência de ocorrência não nula, não sendo, portanto, necessária a utilização de um número maior de níveis na janela equalizada.

3.3 - CARACTERISTICAS DE TEXTURA

A seguir, mostra-se como são obtidas as medidas de textura, a partir de cada uma das matrizes de coocorrência (Haralick, 1973 c). Como estas matrizes são simétricas, na definição de algumas destas medidas, este fato já foi levado em conta.

Sejam:

N... número de níveis de cinza após a equalização da janela
 $p(i,j)$... elemento (i,j) da matriz de coocorrência já normalizada.

$$\text{ALFA}(i) = \sum_{j=1}^N p(i,j) \dots \text{soma dos elementos da } i\text{-ésima linha (ou coluna)}$$

$$\text{BETA}(k) = \sum_{i=1}^N \sum_{\substack{j=1 \\ i+j=k}}^N p(i,j), \quad k = 2, 3, \dots, 2N \text{ soma dos elementos da } k\text{-ésima diagonal secundária}$$

$$\text{GAMA}(k) = \sum_{i=1}^N \sum_{\substack{j=1 \\ |i-j|=k}}^N p(i,j), \quad K = 0, 1, \dots, N-1 \text{ duas vezes a soma dos elementos da } k\text{-ésima diagonal.}$$

$$u = \sum_{i=j}^N \sum_{j=1}^N i p(i,j) = \sum_{i=j}^N i \text{ALFA}(i)$$

$$v = \left[\left[\sum_{j=1}^N \sum_{i=1}^N i^2 p(i,j) \right] - u^2 \right]^{1/2} = \left[\sum_{i=1}^N i^2 \text{ALFA}(i) - u^2 \right]^{1/2}$$

Tem-se, então, as características:

1) Momento angular de 2a. ordem: (ASM)

$$F1 = \sum_{i=1}^N \sum_{j=1}^N \{p(i,j)\}^2$$

2) Contraste: (CONT)

$$F2 = \sum_{n=0}^{N-1} n^2 \text{GAMA}(n)$$

3) Correlação: (COR)

$$F3 = \frac{\left[\sum_{i=1}^N \sum_{j=1}^N i j p(i,j) \right] - u^2}{v^2}$$

4) Variância: (VAR)

$$F4 = \sum_{i=1}^N \sum_{j=1}^N (i-u)^2 p(i,j)$$

5) Momento inverso da diferença: (XIDM)

$$F5 = \sum_{i=1}^N \sum_{j=1}^N \frac{p(i,j)}{1 + (i-j)^2}$$

6) Média da soma: (SUMAVE)

$$F6 = \sum_{i=2}^{2N} i \text{ BETA } (i)$$

7) Variância da soma: (SUMVAR)

$$F7 = \sum_{i=2}^{2N} (i-F6)^2 \text{ BETA } (i)$$

8) Entropia da soma: (SUMENT)

$$F8 = - \sum_{i=2}^{2N} \text{BETA } (i) \ln (\text{BETA } (i))$$

9) Entropia: (ENT)

$$F9 = - \sum_{i=1}^N \sum_{j=1}^N p(i,j) \ln(p(i,j))$$

10) Variância da Diferença:

$$F10 = - \sum_{i=0}^{N-1} (i-DIF)^2 \text{ GAMA } (i), \text{ onde } DIF = \sum_{i=0}^{N-1} i \text{ GAMA } (i)$$

11) Entropia da Diferença: (DIFERENT)

$$F11 = - \sum_{i=0}^{N-1} \text{GAMA } (i) \ln (\text{GAMA}(i))$$

12) Medida adicional de correlação: (CORME)

$$F12 = \frac{F9 - HXY}{HX} \text{ onde:}$$

$$HX = - \sum_{i=1}^N \text{ALFA } (i) \ln (\text{ALFA } (i))$$

$$HXY = - \sum_{i=1}^N \sum_{j=1}^N p(i,j) \ln \{ \text{ALFA } (i) \text{ ALFA } (j) \}$$

Além destas, foram sugeridas mais duas outras medidas de correlação:

$$F13 = (1 - \exp \{-1(HXY^2 - F9)\}), \text{ onde}$$

$$HXY2 = - \sum_{i=1}^N \sum_{j=1}^N ALFA(i) ALFA(j) \ln \{ ALFA(i) ALFA(j) \}$$

F14 = (2º maior autovalor de Q)^{1/2}, onde:

$$Q(i,j) = \sum_{k=1}^N \frac{p(i,k) p(j,k)}{ALFA(i) ALFA(j)}$$

Inicialmente todas as medidas foram implementadas. O F13 geralmente causava problema de "overflow", mesmo com a normalização das matrizes e com utilização de logaritmo decimal no cálculo de F9 e HXY2. O F14, além de exigir uma memória extra, pois a matriz Q deveria ser calculada com precisão estendida, tomava muito tempo da máquina. Por estes motivos não foram mais utilizadas estas duas medidas, na implementação final do programa extrator de características. Em compensação devido à relativa folga de memória, foi possível uma maior interação entre o usuário e o programa, além de grande economia de tempo.

Embora seja difícil explicar o que representa exatamente cada uma destas medidas, é intuitivo, pelo menos para algumas, o seu significado.

Ao se analisar o ASM, vê-se que ele é pequeno quando todos os elementos da matriz são aproximadamente iguais, aumentando a medida que alguns elementos ficam maiores que os outros. Isto pode ser encarado como uma medida de homogeneidade, pois numa imagem homogênea existem poucas transições de níveis de cinza dominantes.

O CONT mede o momento de inércia da matriz em relação à sua diagonal principal. Sendo a medida mais natural do espalhamento dos valores da matriz. Note-se que, se a textura for grossa e a distância d pequena, em relação ao tamanho do elemento de textura, os pares de pontos separados de d devem normalmente ter valores próximos de níveis

de cinza. Isto implica em que os elementos, próximos à diagonal principal, deverão assumir valores elevados. Por outro lado, se a textura for fina e a distância d comparável ao tamanho do elemento de textura, os pares de pontos separados de d terão níveis de cinza mais separados, ou seja, haverá um espalhamento uniforme dos valores da matriz. O CONT medirá, então, a quantidade de variações locais de níveis de cinza, presentes na imagem, ou seja, o contraste.

A correlação (COR) fornece uma medida de quão similares são as linhas ou colunas da matriz de coocorrência. Se os valores são bem distribuídos, tem-se alta correlação, enquanto que, no caso contrário, tem-se baixa correlação (por exemplo, quando os valores longe da diagonal são muito pequenos). Em termos de textura, a correlação fornece uma medida das dependências lineares dos níveis de cinza na imagem (Haralick, 1973 c).

Cada uma das medidas citadas é extraída de uma matriz, sendo, portanto, função da direção e da distância para as quais ela foi obtida. É claro que é bastante informativo o fato de uma certa textura ser direcional, apresentando estruturas em uma certa orientação. Contudo, não se está interessado na direção particular dessas estruturas. É interessante, portanto, que sejam utilizadas características de textura que sejam invariantes à orientação da imagem, mas ao mesmo tempo tragam informação de direcionalidade. Obviamente, não seria o caso de se utilizar diretamente as características obtidas das quatro matrizes.

Foram utilizadas funções dessas características, da seguinte forma: supondo que uma determinada janela tenha características a , b , c e d , correspondendo às quatro direções, obteve-se a média, a faixa de variações e o desvio padrão deste conjunto, os quais são invariantes a uma rotação da janela.

Tem-se, então, um conjunto de 12×3 características de textura que agora poderão ser utilizadas como dados de entrada para o classificador. É certo que existe uma forte dependência entre várias

dessas 36 medidas, e a utilização de todas ao mesmo tempo traria muita informação supérflua ao classificador, sendo, portanto, necessária uma seleção de características. Isto se constitui num problema básico da área de reconhecimento de padrões.

Não consta do presente trabalho um programa de seleção de características. Entretanto, foi implementado um programa (HGRAM) que permite uma comparação das distribuições de duas classes arbitrárias, em relação a uma determinada característica, através de uma discretização dos valores assumidos por esta característica e posterior levantamento dos histogramas relativos às classes escolhidas.

CAPITULO IV

ESTUDO PRINCIPAL

4.1 - DADOS UTILIZADOS

Para este estudo foi utilizada uma imagem do LANDSAT de número 175152-123730-7, do nordeste de Mato Grosso, obtida na passagem do dia 1 de junho de 1975. Um mapa geológico do Departamento Nacional da Produção Mineral, do Ministério das Minas e Energia, foi usado para separar três tipos principais de terreno existentes:

Tipo A: Pré-cambriano

Tipo B: Coberturas detríticas

Tipo C: Pleistoceno

A Figura IV.1 mostra a banda nº 7 da imagem (infravermelho intermediário), que foi escolhida para análise de textura. Foram selecionadas 182 janelas de 62 x 62 pontos, sendo 57 da categoria A, 62 da B e 62 da C.

4.2 - PROCEDIMENTO

Usou-se a mesma resolução obtida com o LANDSAT, ou seja, cada ponto da imagem no sistema I-100, correspondente a exatamente um ponto da imagem do LANDSAT. Como esta é composta de 3240 x 2340 pontos, e a capacidade máxima da memória de imagem do sistema I-100 é de 512 x 512 pontos, foram necessárias várias etapas para que toda a imagem fosse processada.

Considerando-se a resolução da imagem do LANDSAT, onde cada ponto representa uma área de cerca de 70 m x 60m, foi usada a distância unitária para obtenção das matrizes de coocorrência.




Fig. IV.1 - Imagem LANDSAT do nordeste do Mato Grosso.

dualmente dá o melhor resultado e, em seguida, uma terceira, que junto com aquele par, dá o melhor resultado e assim por diante.

No caso deste trabalho não se trata do problema da procura de um conjunto ótimo de características, mas de uma análise da importância das características de textura em geral. Portanto, para uma classificação com pares de características, foram escolhidas as médias de todos os tipos de medidas de textura (12 no total), além da faixa de variação e do desvio padrão do XIDM, que foram exatamente as características de textura de melhor desempenho individual. Das características espectrais, foram desprezadas as duas que deram piores resultados, ou seja 4-V e 5-V.

Fica-se, então, com um total de 20 características para serem utilizadas em classificações, através de pares de características. Os resultados obtidos, quando o classificador usado é o Mín-Máx, encontram-se na Tabela IV.2.

O melhor resultado, encontrado com a utilização de pares de características de textura, foi de 85 acertos em 91 possíveis, ou seja, uma percentagem de classificação correta de 93,4%. Isto foi obtido com o uso das características XIDM-D e CORME-M.

Já o melhor resultado, com características espectrais, foi de 87 acertos (95,6%), obtido com o uso das características 7-M e 7-V.

O melhor resultado geral foi 90 acertos, correspondendo a 98,9% de classificação correta, e obtido com um par misto de características, ou seja, uma textural (SUMENT-M) e outra espectral (7-M).

De forma global, os melhores resultados foram os obtidos com pares mistos de características. Isto pode ser melhor compreendido com a ajuda das Figuras IV.2 - IV.6, onde estão colocados alguns histogramas obtidos, usando-se o conjunto inteiro das 182 janelas. Nestas Figuras, as classes 1, 2 e 3 são usadas para designar, respectivamente, os tipos de terreno A, B e C.





Fig. IV.2 - Características: ASM-M





Fig. IV.3 - Característica: XIDM-D





Fig. IV.4 - Característica: ENT-M





Fig. IV.5 - Característica: CORME-M

Seja o histograma da imagem no canal, em que a textura vai ser utilizada para efeito de classificação $A(i)$, $i=0,255$. A partir dele, obtêm-se a função de distribuição acumulada dos níveis de cinza, conforme a Figura III.2.




Fig. III.2 - Função de distribuição acumulada

qualização mais refinada. Como isto, forçosamente, demandaria um tempo considerável, resolveu-se fazer, simplesmente, uma escolha pela melhor colocação daquele nível original em um dos dois níveis transformados, não sendo portando, a equação (1) seguida à risca.

Seria interessante citar que, pelo menos na imagem utilizada, normalmente uma janela de 62×62 pontos não apresenta mais que 40 níveis de cinza, com frequência de ocorrência não nula, não sendo, portanto, necessária a utilização de um número maior de níveis na janela equalizada.

3.3 - CARACTERÍSTICAS DE TEXTURA

A seguir, mostra-se como são obtidas as medidas de textura, a partir de cada uma das matrizes de coocorrência (Haralick, 1973c). Como estas matrizes são simétricas, na definição de algumas destas medidas, este fato já foi levado em conta.





Fig. IV.6 - Característica: 7-M

A Figura IV.2 mostra os histogramas para o ASM-M. Pode-se ver que existe boa separação entre as classes 1 e 2, e deduzir-se que a separação é melhor ainda para as classes 1 e 3. Como o terreno do tipo 2 é mais homogêneo que o do tipo 1, era esperado que os valores assumidos pelo ASM fossem maiores para o tipo 2, o que de fato aconteceu.

A Figura IV.3 mostra os histogramas para o XIDM-D, onde se pode ver que, embora haja certa interseção entre as classes 2 e 1, e 2 e 3, para as classes 1 e 3 ela já é menor. Na realidade, a existência de interseção não implica na inutilidade da característica, pois o simples fato das médias dos valores desta característica serem diferentes, para classes diferentes, já mostra que ela é informativa.

Da mesma forma, podem ser interpretadas as Figuras IV.4 para o ENT-M, e IV.5 para o CORME-M.

A Figura IV.6 mostra as distribuições das classes, quando a característica usada é a média espectral da janela na banda 7 (7-M), que foi utilizada para extração de informação sobre a textura. Pode-se ver que a classe 3 é bem separada da classe 2, e deduzir que a separação é um pouco menor com relação à classe 1. Isto é devido ao fato de que a maior parte do terreno tipo C é bem escura, diferenciando-se dos demais tipos, o que pode ser visualizado na Figura IV.1.

Desta forma, já eram esperados os resultados obtidos, uma vez que em geral as características de textura, usadas individualmente, separam bem as classes 1-2 e 1-3, enquanto que as espectrais (em especial 7-M) separaram bem as classes 2-3.

As medidas espectrais do tipo variância, via de regra, tiveram desempenho mais fraco que as do tipo média, quando usadas em pares mistos de características. Porém, notou-se que os pares de características espectrais, com melhores resultados, foram aqueles que usaram uma do tipo média e a outra do tipo variância.

Em seguida, foi realizado um estudo de classificação, utilizando-se a dimensão do espaço de características igual a 3. Utilizando-se as 20 características anteriores, podiam ser feitas 1140 combinações diferentes para classificação. No entanto, foram consideradas apenas 12 características, sendo 9 texturais e 3 espectrais. As espectrais foram 7-M, 7-V e 6-M. O critério usado para seleção das 9 características de textura foi a soma total de acertos dos pares de características, dos quais cada uma dessas 9 características fez parte, o que pode ser obtido da Tabela IV.2. Foram, então, escolhidas as características ASM-M, VAR-M, XIDM-M, XIDM-D, XIDM-F, SUMVAR-M, SUMENT-M, ENT-M e CORME-M. As tabelas IV.3 - IV.11 mostram os resultados obtidos. A característica chave, indicada, é aquela que sempre foi utilizada para, em conjunto com duas outras constantes da Tabela, fornecer o resultado assinalado.

Várias combinações de características de textura forneceram um resultado de 87 acertos, em 91 possíveis, dando uma percentagem de classificação correta de 95,6%, que foi o máximo obtido com características deste tipo. O melhor resultado obtido foi de 90 acertos (98,9%), com o conjunto formado pelas características XIDM-M, SUMENT-M e 7-M. Apresentam-se, a seguir, as Tabelas de IV.1 a IV.11, mencionadas anteriormente.

TABELA IV.1

NÚMERO DE JANELAS CLASSIFICADAS CORRETAMENTE
UTILIZANDO-SE CARACTERÍSTICAS INDIVIDUAIS

CARACTERÍSTICA	MIN-MAX	VMP	CARACTERÍSTICA	MIN-MAX	VMP
ASM-M	62	66	SUMENT-D	48	41
ASM-D	69	72	SUMENT-F	49	44
ASM-F	68	65	ENT-M	63	66
CONT-M	48	52	ENT-D	41	38
CONT-D	52	57	ENT-F	44	49
CONT-F	48	54	DIFVAR-M	33	45
COR-M	61	54	DIFVAR-D	39	40
COR-D	46	54	DIFVAR-F	41	46
COR-F	42	47	DIFENT-M	59	64
VAR-M	51	42	DIFENT-D	53	49
VAR-D	31	34	DIFENT-F	54	55
VAR-F	32	39	CORME-M	53	51
XIDM-M	64	63	CORME-D	56	53
XIDM-D	77	76	CORME-F	53	48
XIDM-F	77	74	4-M	51	67
SUMAVE-M	55	50	4-V	38	52
SUMAVE-D	42	42	5-M	65	61
SUMAVE-F	35	44	5-V	39	64
SUMVAR-M	61	48	7-M	79	77
SUMVAR-D	50	53	7-V	60	62
SUMVAR-F	44	46	6-M	81	71
SUMENT-M	61	65	6-V	54	59

✓

[illegible]

CARACTERÍSTICA CHAVE: VAR-M

[illegible]

TABELA IV.5
CARACTERÍSTICA CHAVE: XIDM-M

	XIDM-F	SUMVAR-M	SUMENT-M	ENT-M	CORME-M	7-M	7-V	6-M
XIDM-D	82	85	84	84	85	87	84	86
XIDM-F		84	83	83	84	86	83	85
SUMVAR-M			83	83	84	88	79	86
SUMENT-M				77	87	90	79	87
ENT-M					86	89	79	86
CORME-M						84	83	85
7-M							87	87
7-V								85

TABELA IV.6

CARACTERÍSTICA CHAVE: XIDM-D

	SUMVAR-M	SUMENT-M	ENT-M	CORME-M	7-M	7-V	6-M
XIDM-F	81	78	79	85	86	82	86
SUMVAR-M		82	83	85	87	83	86
SUMENT-M			80	87	87	83	87
ENT-M				87	87	83	87
CORME-M					86	84	86
7-M						85	86
7-V							85

TABELA IV.7

CARACTERÍSTICA CHAVE: XIDM-F

	SUMENT-M	ENT-M	CORME-M	7-M	7-V	6-M
SUMVAR-M	81	82	85	86	81	85
SUMENT-M		79	86	86	82	86
ENT-M			86	86	82	86
CORME-M				85	83	85
7-M					84	85
7-V						84

TABELA IV.8

CARACTERÍSTICA CHAVE: SUMVAR-M

	ENT-M	CORME-M	7-M	7-V	6-M
SUMENT-M	76	82	89	76	86
ENT-M		82	89	77	86
CORME-M			85	77	84
7-M				87	86
7-V					86

TABELA IV.9

CARACTERÍSTICA CHAVE: SUMENT-M

	CORME-M	7-M	7-V	6-M
ENT-M	82	89	71	87
CORME-M		89	79	88
7-M			87	89
7-V				85

TABELA IV.10

CARACTERÍSTICA CHAVE: ENT-M

	7-M	7-V	6-M
CORME-M	88	79	87
7-M		87	88
7-V			85

TABELA IV.11

CARACTERÍSTICA CHAVE: CORME-M

CONJUNTO USADO	Nº DE ACERTOS
CORME-M, 7-M, 7-V	86
CORME-M, 7-M, 6-M	82
CORME-M, 7-V, 6-M	85
7-M, 7-V, 6-M	87

De uma maneira geral houve um melhor desempenho com a introdução de uma terceira característica, o que pode ser visto confrontando-se a Tabela IV.2 com as seguintes. Por exemplo, o par ASM-M e VAR-M acertou 75 vezes e, com a introdução de mais uma característica, obtiveram-se resultados maiores ou iguais a 75, o que pode ser visto na 1a. linha da Tabela IV.3. Isto acontece praticamente com todos os pares de características de textura, onde a nova característica introduzida traz bastante informação sobre a separação das classes 2 e 3. Nos pares mistos de características isto, entretanto, não é verdade: por exemplo: o par ASM-M e 7-M que apresentou 88 acertos, com a introdução de mais uma característica, diminuiu ou manteve este desempenho (Tabela IV.3, 3a. coluna da direita para a esquerda). Isto se deve a dois efeitos antagônicos envolvidos: um, que é a informação adicional contida na característica, e outro, que é a sensibilidade demonstrada pelo M_{ín}-M_{áx}, a um aumento de dimensionalidade. No Apêndice A.1.1 será comentado este segundo efeito.

De uma maneira geral, pode-se considerar, pelo menos, razoáveis os resultados obtidos com trincas dessas características de textura. O m_{ín}imo de acertos foi 62 (68%), o m_{áx}imo foi 87 (95,6%), e a mêdia foi em torno de 81 acertos (89%).

Embora aumentando o tempo consumido, o aumento de dimensio nalidade do espaço de características não afeta o desempenho do classifi cador, baseado na regra de decisão do vizinho mais próximo (VMP). Na Ta**be**la IV.12 estão alguns resultados obtidos, quando se utilizou a dimensão do espaço igual a 4. Neste caso, fez-se uso de características que deram os melhores resultados, quando usadas em trincas.

Como se pode observar na Tabela IV.12, o conjunto de carac terísticas de textura ASM-M, VAR-M, XIDM-F e CORME-M obteve 100% de clas sificação correta, quando o VMP foi usado. Na verdade, este resultado não se torna muito raro, quando são utilizadas dimensões maiores que 6.

A esta altura, talvez seja interessante comparar alguns re sultados encontrados, com outros existentes. Wieszka et al (1976) fazem uma análise comparativa de medidas de textura, com fins de classificação de terrenos. Embora as medidas realizadas sobre as matrizes de coocorrência sejam utilizadas, diretamente, como características de textura (havendo, portanto, sensibilidade à orientação), pode-se notar dois fatos:

- 1) A entropia (ENT) deu resultados similares aos obtidos com o mo mento angular de 2a. ordem (ASM), quando utilizados individual mente. No caso deste trabalho, isto também ocorreu com relação às médias destes tipos de medidas (Tabela IV.1).
- 2) O XIDM deu resultados piores que o ASM e o ENT, quando usados in dividualmente, ou em conjunto formados por um mesmo tipo de medi da, computada para várias distâncias e direções. Como sô se usou distância unitária, não se pode confirmar a segunda parte deste resultado. Quanto à primeira parte, pode-se ver, pelos resultados apresentados em Wieszka et al (1976), que o desempenho do XDM di minui nitidamente com a distância utilizada, embora, mesmo com distância unitária, ele já seja inferior aos desempenhos do ASM e do ENT. No presente trabalho, se se considerar o XIDM-M como sendo a característica mais próxima das medidas diretas sobre as matrizes, pode-se ver que os resultados não diferem muito (os de

sempenhos do XIDM-M, ASM-M e ENT-M foram 64, 62 e 63, respectivamente), embora o XIDM-M tenha sido um pouco melhor. Entretanto, o XIDM-D e o XIDM-F, individualmente, apresentaram os melhores desempenhos de todas as características de textura implementadas. Essa diferença talvez seja devido ao fato de que uma característica de textura, do tipo desvio padrão ou faixa de variação, está muito mais relacionada à direcionalidade, do que, propriamente, à rugosidade da textura, que é o que está, basicamente, sendo medido através das características usadas em Weszka, 1976. Ou seja, pelo fato do XIDM-M ter tido um desempenho fraco, não necessariamente o XIDM-D ou XIDM-F devem fornecer maus resultados.

TABELA IV.12

CONJUNTO DE CARACTERÍSTICAS

CONJUNTO DE CARACTERÍSTICAS	MIN-MAX	VMP
ASM-M, VAR-M, XIDM-D, CORME-M	86	90
ASM-M, VAR-M, XIDM-F, CORME-M	83	91
ASM-M, VAR-M, CORME-M, 7-M	86	89
ASM-M, XIDM-M, XIDM-D, SUMVAR-M	83	87
VAR-M, XIDM-M, XIDM-D, SUMVAR-M	84	85
VAR-M, ENT-M, CORME-M, 7-M	87	89
XIDM-M, XIDM-D, SUMVAR-M, SUMENT-M	85	87
XIDM-M, SUMENT-M, CORME-M, 7-M	89	88
XIDM-D, SUMENT-M, ENT-M, CORME-M	87	86
XIDM-D, ENT-M, CORME-M, 7-M	86	90
SUMENT-M, CORME-M, 7-M, 6-M	88	85
SUMENT-M, 7-M, 7-V, 6-M	87	87

4.4 - CONCLUSÕES

De maneira geral podem ser considerados bons os resultados obtidos, utilizando-se apenas características de textura na discriminação de tipos diferentes de terreno. Mesmo tendo sido utilizada uma imagem em que não era tão óbvia a separação visual, através de textura, de uma das classes (tipo C), os índices de classificação correta chegaram a atingir várias vezes 95,6%, quando o MIn-Máx foi utilizado, e outras vezes chegaram a 100% com o uso do VMP. Os tipos de medidas de textura ASM, XIDM, SUMENT, ENT e CORME foram os que, em geral, forneceram os melhores resultados. O CORME, que ainda não havia sido testado nos trabalhos anteriores, forneceu uma boa opção para distinção entre as classes B e C, as quais, em geral, não foram bem separadas com características de textura individuais (Figuras IV.2 - IV.6)

Globalmente, os melhores resultados ficaram por conta dos conjuntos mistos de características, ou seja, os que utilizavam tanto características espectrais como de textura. Esta conclusão está de pleno acordo com o que foi obtido em Haralick e Bosley (1973a). Entretanto, seria bom frisar que o uso de conjuntos mistos de características está restrito à discriminação entre categorias dentro de uma mesma imagem, uma vez que as características espectrais de uma mesma classe podem variar sensivelmente, de acordo com as condições sob as quais a imagem foi obtida. Desto fato é que decorre a grande vantagem das características texturais sobre as espectrais, uma vez que antes do processamento é realizada a equalização do histograma, que as torna invariantes a condições diferentes, que porventura existam em imagens distintas.

AGRADECIMENTOS

Ao pessoal do IMAGE-100, que em muito contribuiu para a execução do presente trabalho.

À Aparecida Alves Cardoso pela datilografia do relatório final.

A todos que de alguma forma colaboraram para a realização deste trabalho.

55

BIBLIOGRAFIA

- DYER, C.R.; WESZKA, J.S.; ROSENFELD, A. *Experiments in terrain classification on LANDSAT imagery by texture analysis*. College Park, MD., University of Maryland. Computer Science Center, 1975. (Technical Report, 383).
- FUKUNAGA, K. *Introduction to statistical pattern recognition*. New York, Academic, 1972.
- GENERAL ELECTRIC COMPANY. *IMAGE-100 - System software description*. Daytona Beach, 1974a.
- . *IMAGE-100: user manual*. Daytona Beach, 1974b.
- HALL, E.E.; HALL, E.L.; KRUGER, R.P.; DWYER, S.J.III; HALL, D.L.; McLAREN, R.W.; LODWICK, G.S. A Survey of Preprocessing and Feature Extraction Techniques for Radiographic Images. *IEEE Transactions Computers*, C-20(9): 1032-1044, Sep., 1971.
- HARALICK, R.M.; BOSLEY, R. Spectral and Textural Processing of ERTS Imagery. In: *EARTH Resources Technology Satellite-1 Symposium*, 3., Washington, DC., 1973. Proceedings. V.1, p.1929-1969.
- .; SHANMUGAN, K. Computer Classification of Reservoir Sandstones. *IEEE Transactions Geoscience Electronics*, GE-11 (4): 171-177, Oct., 1973b.
- .; DINSTEIN, I. Textural Features for Image Classification. *IEEE Transactions on Systems, man, and cybernetics*, SMC-3 (6): 610-621, Nov., 1973c.
- HAWKINS, J.K. Textural Properties for Pattern Recognition. In: LIPKIN, B.S.; ROSENFELD, A., ed. *Picture processing and psychopictorics*. New York, Academic, 1970.

JULESZ, B. Texture and Visual Perception. *Scientific American*, 212 (2): 38-55, Feb., 1965.

———., Experiments in the Visual Perception of Texture. *Scientific American*, 234 (4): 34-44, Apr., 1975.

MEISEL, W. *Computer Oriented Approaches to Pattern Recognition*. New York, Academic, 1972.

PICKETT, R.M. Visual Analysis of Texture in the Detection and Recognition of Object. In: LIPKIN, B.S.; ROSENFELD, A., ed. *Picture processing and psychopictories*. New York, Academic, 1970.

ROSENFELD, A. *Picture Processing by Computer*. New York, Academic, 1969.

TEKTRONIX *Plot-10 terminal control system: user manual*. Beaverton, DR., Tektronix, 1974.

TOU, J.T. and GONZALES, R.C. *Pattern Recognition Principles*. Reading MA., Addison-Wesley, 1974.

WESZKA, J.S.; DYER, C.R.; ROSENFELD, A. A Comparative Study of Texture Measures for Terrain Classifications. *Transactions on Systems, Man, and Cybernetics*, SMC-6 (4): 269-285, Apr., 1976.

APÊNDICE A

PROCEDIMENTOS DE CLASSIFICAÇÃO

No programa CATEG, desenvolvido para realizar a etapa de classificação propriamente dita, podem ser utilizados dois classificadores: o Mín-Máx e o do vizinho mais próximo.

A.1 - O CLASSIFICADOR MÍN-MÁX

Seja uma amostra designada por um vetor de N características $X = (x_1, x_2, \dots, x_N)$. Este classificador utiliza uma regra de decisão que é de máxima verossimilhança sob a hipótese de que as características são independentes e possuem distribuição uniforme. Se isto for admitido, tem-se que a função densidade de probabilidade para a categoria k é:

$$f(X|k) = \frac{1}{(a_{nk} - b_{nk})}, \text{ para todo } X \text{ tal que}$$

$$b_{nk} \leq x_n \leq a_{nk}, n=1, \dots, N$$

onde, nesta expressão, a_{nk} e b_{nk} definem os valores máximo e mínimo da distribuição uniforme da categoria k , para a componente n .

Assim, uma amostra (x_1, x_2, \dots, x_N) é atribuída a categoria k , se e só se:

$$1) b_{nk} \leq x_n \leq a_{nk}, n=1, 2, \dots, N$$

$$2) \frac{1}{(a_{nk} - b_{nk})} \geq \frac{1}{(a_{nj} - b_{nj})}, \text{ para todo } j, \text{ tal que}$$

$$b_{nj} \leq x_n \leq a_{nj}, n=1, 2, \dots, N$$

Se não existir k , tal que $b_{nk} \leq x_n \leq a_{nk}$, $n=1,2,\dots,N$, então, X é atribuído à categoria k , se esta for a categoria que minimize o termo

$$\sum_{n=1}^N (*) (\min\{|x_n - a_{nj}|, |x_n - b_{nj}|\})^2, j=1,2,\dots, K$$

onde K é o número de categorias e o $(*)$ foi colocado para indicar que não se incluem no somatório, os termos cujos n 's são tais que $b_{nj} \leq x_n \leq a_{nj}$.

A estimativa do intervalo $b_{nk} - a_{nk}$ da distribuição uniforme da categoria k , para a componente n , é feita da seguinte forma: Sejam A_{nk} e B_{nk} os valores máximo e mínimo da componente n , para todas as amostras designadas na categoria k , e M_k , o número dessas amostras. Então:

$$b_{nk} = B_{nk} - \frac{A_{nk} - B_{nk}}{M_k - 1}$$

$$a_{nk} = A_{nk} + \frac{A_{nk} - B_{nk}}{M_k - 1}$$

Vê-se que o intervalo da distribuição uniforme é um pouco maior que o encontrado na fase de treinamento, isto é:

$$a_{nk} - b_{nk} = (A_{nk} - B_{nk}) \cdot \frac{M_k - 1}{M_k - 1}$$

Nota-se que é bastante simples o funcionamento do M̄n-M̄x. Na fase de treinamento, é determinado o N-paralelepípedo correspondente a cada uma das categorias existentes. Quando, na fase de classificação, uma amostra é apresentada ao classificador, este verifica em qual paralelepípedo ela está contida. Podem então ocorrer 3 casos:

- 1) O paralelepípedo é único: então a amostra é classificada como sendo da categoria correspondente.
- 2) O paralelepípedo não é único: então a classe correspondente ao menor deles é atribuída, pois, de acordo com a hipótese feita, ela é a mais provável.
- 3) A amostra não pertence a nenhum paralelepípedo. Neste caso, procura-se aquele paralelepípedo que está mais perto da amostra, e a classe desse é atribuída à amostra.

O terceiro caso envolve cálculo de distâncias euclidianas, no espaço de características. Como, certamente, as características não têm a mesma ordem de grandeza, é necessária uma normalização, de modo a se atribuir pesos iguais para todas elas. Foi feito um mapeamento linear em cada dimensão do espaço de características, independentemente da classe das amostras, de modo que os valores assumidos variassem entre 0 e 1.

Quando da utilização do Mín-Máx, o conjunto total de amostras foi dividido em duas partes iguais: 91 amostras para treinamento, ou determinação dos parâmetros das distribuições pelo classificador, e 91 amostras para teste. Foi verificado que, quando era aumentada a dimensão do espaço de características, crescia o número de ocorrências de classificações, pelo terceiro critério citado, ou seja, mais amostras não pertenciam a nenhum dos paralelepípedos existentes. Isto talvez seja consequência de uma estimativa do intervalo da distribuição uniforme de cada classe, para cada característica, baseada em um número insuficiente de amostras. Como no caso deste trabalho as classes não eram separadas, o uso daquele critério era o que mais resultava em erros de classificação.

Para simplificar uma análise, considerar-se-á o caso em que o intervalo da distribuição, uniforme em cada componente, é estimado como sendo a diferença entre os valores máximo e mínimo das amostras para esta componente. Supondo-se que se faça tal estimativa, baseados em duas amostras apenas, X_1 e X_2 , e que as características sejam realmente independentes e uniformemente distribuídas entre 0 e 1, pode-se, então, calcu

lar a probabilidade de que, pelo menos, uma fração w das amostras venha cair fora do intervalo estimado, no caso de dimensão igual a 1 (Figura A.1).




Fig. A.1 - Funções densidade de probabilidade.

A largura do intervalo estimado $\bar{e} t = |x_1 - x_2|$; e a probabilidade que se procura \bar{e} (Figura A.1).

$$P [1 - |X_1 - X_2| \geq w] = P [|X_1 - X_2| \leq 1 - w]$$

Calculando-se este valor, através da função densidade de probabilidade de variável aleatória $|X_1 - X_2|$, apresentada na Figura A.1, tem-se:

$$P [|X_1 - X_2| \leq 1 - w] = \int_0^{1-w} (2-2y) dy = 1 - w^2$$

Calcule-se agora a probabilidade de que, pelo menos, uma fração y das amostras caiam fora do intervalo estimado, no caso de dimensão igual a 2 (Figura A.2).




Fig. A.2 - Intervalos bidimensionais.

A partir da Figura A.2, e levando-se em conta o resultado do anterior, tem-se que:

$$P [1 - |X_{1a} - X_{2a}| \geq a, 1 - |X_{1b} - X_{2b}| \geq b] = (1 - a^2) (1 - b^2)$$

é a probabilidade de que, pelo menos, uma fração $1 - (1-a) (1-b)$ das amostras caiam fora da região estimada.

Fixando-se uma certa probabilidade, e comparando-se as frações mínimas esperadas de amostras, caindo fora do intervalo estimado para os casos de dimensão 1 e 2, pode-se ver que é realmente esperado um número maior de amostras fora da região estimada, para o caso de dimensão

2. Por exemplo, com uma probabilidade 90%, espera-se que, pelo menos, 31,6% das amostras caiam fora para o caso de dimensão 1, ao passo que, com di mensão 2, esta percentagem mínima se eleva a 40,2%.

Para uma estimativa baseada em um número muito grande de amostras, a situação não é tão simples assim. Porém, é razoável que ainda neste caso, aumente o número de amostras caindo fora do intervalo, para um aumento de dimensionalidade, uma vez que, para uma amostra cair dentro de uma região a N dimensões, ela precisa estar dentro de cada um dos N in tervalos correspondentes.

Como se pode verificar na descrição do M̄in-M̄ax, a largura do intervalo estimado da distribuição uniforme, para cada componente, não é exatamente a encontrada através das amostras de treino, pois existe um fator multiplicativo maior que a unidade, e que é função do número dessas amostras. Entretanto, ainda assim foi verificado um crescimento do número de amostras em teste caindo fora do paralelepípedo estimado, com o aumen to de dimensionalidade.

A.2 - REGRA DE DECISÃO DO VIZINHO MAIS PRÓXIMO

Seja um conjunto de amostras, com classificação conhecida, $\{s_1, s_2, \dots, s_N\}$, e X a amostra sendo classificada. A regra de classifica_{ção} do vizinho mais próximo consiste em atribuir a X a classe do seu vi zinho mais próximo, s^* , onde s^* é tal que:

$$D(s^*, X) = \min \{D(s_\ell, X), \ell = 1, 2, \dots, N\}$$

Nesta expressão, D pode ser qualquer medida de distância. No caso deste trabalho, a distância utilizada foi a própria euclideana.

De modo a se atribuir a mesma importância a todas as características, deve-se realizar uma normalização, de maneira que todas assumam valores dentro de um mesmo intervalo.

Este classificador, embora mais elementar que o Mín-Máx, apresenta a desvantagem de ter uma velocidade de classificação menor e mais dependente da dimensão do espaço de características.

APÊNDICE B

LISTAGENS DOS PROGRAMAS

FORTRAN IV V01B-02
CORE=08K, UIC=[200,200]

FRI 26-NOV-75 20:19:53

PAGE 001

COLETA,LP:/LI:1=DT1:COLETA.

000000

PROGRAMA PARA OBTENCAO SISTEMATICA DE CARACTERISTICAS
ESPECTRAIS E DE TEXTURA PARA FINS DE CLASSIFICACAO

```

0001 LOGICAL*1 W(74),IZ,TABLE(256),BUFF(512,2),BUF(512)
0002 REAL*4 VPW(12),VRW(12),XVAP(4),XMEDIA(4)
0003 REAL *4 VQW(12),FEDEP(12),FEMED(12),FERAG(12),VSW(12),VW(12)
0004 INTEGER LX(3,5),CX(2,4),EC(2,2),IC(2,2),CC(2,2)
0005 INTEGER SC(2,2),AR(256,4),NR(2),CHN,DIST,LENA(4),NORM(4)
0006 COMMON P(32,32),ALFA(32),BETA(64),GAMA(32)
0007 EQUIVALENCE(NI,IZ),(BUF(1),BUFF(1,1))
0008 EQUIVALENCE (CC(2,2),MAP),(CC(1,2),IAR),(CC(1,1),KAR)
0009 CALL OUTPUT(27,12)
0010 WRITE(6,5)
0011 5 FORMAT(13X,'*** EXTRACAO DE CARACTERISTICAS ***',/)
0012 WRITE(6,10)
0013 10 FORMAT(1X,'A IMAGEM DEVE TER SIDO CARREGADA USANDO A MESMA
C ESCALA DO ERTS')
0014 8999 WRITE(6,9000)
0015 9000 FORMAT('SPRIMEIRA VEZ QUE USA O PROGRAMA(S/N)?>')
0016 CALL OUTPUT(7)
0017 READ(6,20)W
0018 CALL FRONT(W,74)
0019 IF(W(1).EQ.'116')GO TO 9001
0021 IF(W(1).NE.'123')GO TO 8999
0023 CALL FDBSET(3)
0024 GO TO 9010
0025 9001 IWED=1
0026 CALL FDBSET(3,'OLD')
0027 WRITE(6,9002)
0028 9002 FORMAT('QUANTAS JANELAS FORAM PROCESSADAS?>')
0029 CALL OUTPUT(7)
0030 READ(6,20)W
0031 CALL FRONT(W,74)
0032 L=0
0033 CALL INTFF(L,W,74,MPEC)
0034 9010 CALL ASSIGN(3,'DT0:TAR.DAT')
0035 DEFINE FILE 3 (200,100,U,NREC)
0036 IF(IWED.EQ.1)MPEC=MPEC+1
0038 IF(IWED.NE.1) MREC=1
0040 12 WRITE(6,11)
0041 11 FORMAT('DISTANCIA(1-3) E CANAL(1-4) A USAR?>')
0042 CALL OUTPUT(7)
0043 READ(6,20)W
0044 20 FORMAT(74A1)
0045 CALL FRONT(W,74)
0046 L=0
0047 CALL INTFF(L,W,74,DIST)
0048 CALL INTFF(L,W,74,CHN)
0049 IF(DIST.GT.3.OR.CHN.GT.4.OR.DIST.LT.1.OR.CHN.LT.1)GO TO 12
0051 30 DO 50 J=1,2
0052 WRITE(6,40)J,J
0053 40 FORMAT('SBATA EX',I1,'.BY',I1,':',2X)
0054 CALL OUTPUT(7)

```

FORTRAN IV V01B-02
CORE=08K, UIC=(200,200).

FRI 26-NOV-76 20:19:53

PAGE 002

COLETA, LP:/LI:1=DI1:COLETA.

```

0055      READ(6,20)W
0056      CALL FRONT(W,74)
0057      IF(W(1).EQ."130)GO TO 2000
0059      L=0
0060      DO 50 K=1,2
0061  50    CALL INTFF(L,W,74,EC(K,J))
0062      IF(EC(1,2).LE.EC(1,1).OR.EC(2,2).LE.EC(2,1))GO TO 30
0064  60    DO 80 J=1,2
0065      WRITE(6,70)J,J
0066  70    FORMAT('SBATA IX',11,'IY',11,':',2X)
0067      CALL OUTPUT(7)
0068      READ(6,20)W
0069      CALL FRONT(W,74)
0070      IF(W(1).EQ."130)GO TO 2000
0072      L=0
0073      DO 80 K=1,2
0074  80    CALL INTFF(L,W,74,IC(K,J))
0075      IF(IC(1,2).LE.IC(1,1).OR.IC(2,2).LE.IC(2,1))GO TO 60
0076      C ESCOLHA E DETERMINACAO DOS PARAMETROS DA JANELA
0077  89    CALL JANELA(EC,IC,CC,SC,JOB,IDX,IDY)
0078      IF(JOB.EQ.0)GO TO 2000
0080  27    WRITE(6,90)
0081  90    FORMAT('SQUAL A CATEGORIA DA JANELA ESCOLHIDA?>')
0082      CALL OUTPUT(7)
0083      READ(6,20)W
0084      CALL FRONT(W,74)
0085      L=0
0086      CALL INTFF(L,W,74,ICLASS)
0087      IF(ICLASS.LT.1)GO TO 27
0089      CALL ASSIGN(5,'LP:')
0090      C OBTENCAO DO HISTOGRAMA E CAPACTERISTICAS ESPECTRAIS
0091      DO 120 J=1,4
0092      LX(1,J)=0
0093  120    LX(2,J)=0
0094      LX(3,J)=1
0095      LX(1,5)=-1
0096      CALL IWHL(LX)
0097      DO 150 J=1,255,2
0098      DO 140 I=1,4
0099  140    DO 140 K=1,3
0100      LX(K,1)=LX(K,I)+2
0101      CALL IRHC(CX)
0102      CALL IWHL(LX)
0103      DO 145 M=1,4
0104  145    DO 145 K=0,1
0105  150    AR(J+K,M)=CX(K+1,M)
0106      CONTINUE
0107      CALL IPTOT(LENA)
0108      CALL IRTOT(LENA)
0109      XAREA=RTOT(LENA,2)
0110      DO 170 M=1,4
0111      XMEDIA(M)=0.0
0112      XVAR(M)=0.0
0113      DO 160 J=2,256
0114      ACUM=RUS(AR(J,M))
0115      XMEDIA(M)=XMEDIA(M)+(J-1)*ACUM

```

FORTRAN IV VO1B-02 FRI 26-NOV-76 20:19:53 PAGE 003
CDRE=08K, UIC=[200,200] COLETA,LP:/LI:1=DT1;COLETA.

```
0115 160 XVAR(M)=XVAR(M)+(J-1)*ACUM*(J-1)
0116 XMEDIA(M)=XMEDIA(M)/XAREA
0117 XVAR(M)=XVAR(M)/XAREA-XMEDIA(M)*XMEDIA(M)
0118 170 CONTINUE
      C EQUALIZACAO DO CANAL ESCOLHIDO EM 32 NIVEIS PARA O CANAL 5
0119 AREA=0.0
0120 DO 173 J=1,256
0121 173 AREA=AREA+RUS(AR(J,CHN))
0122 WRITE(6,175)CHN
0123 175 FORMAT(10X,'INICIO DA EQUALIZACAO DO CANAL',I2)
0124 ACUM=RUS(AR(1,CHN))
0125 NI=ACUM*32/AREA
0126 IF(NI.EQ.0)GO TO 176
0128 TOTA=AREA*NI/32
0129 IF(ACUM.GT.TOTA+AREA/64)GO TO 176
0131 NI=NI-1
0132 176 K=NI
0133 NI=NI+1
0134 TABLE(1)=I2
0135 DO 190 J=2,256
0136 SADI=RUS(AR(J,CHN))
0137 ACUM=ACUM+SADI
0138 NI=ACUM*32/AREA
0139 IF(NI.EQ.K)GO TO 180
0141 TOTA=AREA*NI/32
0142 TOTA=ACUM*SADI
0143 IF((TOTA+ACUM)/2.GT.TOTA)GO TO 178
0145 NI=NI-1
0146 178 K=NI
0147 180 NI=NI+1
0148 IF(NI.GT.32) NI=32
0150 190 TABLE(J)=I2
0151 LIVV=CC(2,1)-3
0152 LSVV=CC(2,2)+3
0153 LIVH=CC(1,1)-3
0154 LSVH=CC(1,2)+3
0155 DO 220 L=LIVV,LSVV
0156 CALL IRV(CHN,L,BUF)
0157 CALL WAIT
0158 DO 210 J=LIVH,LSVH
0159 K=IBYTE(J-1,BUF)+1
0160 210 BUF(J)=TABLE(K)
0161 CALL INV(5,L,BUF)
0162 CALL WAIT
0163 220 CONTINUE
      C OBTENCAO DAS MATRIZES DE COOCORRENCIA
0164 MN=CC(1,1)+DIST
0165 NORM(1)=2*(IDX-DIST)*IDY
0166 NORM(2)=2*(IDY-DIST)*IDX
0167 NORM(3)=2*(IDX-DIST)*(IDY-DIST)
0168 NORM(4)=NORM(3)
0169 MODD=1
0170 NB(1)=2
0171 NB(2)=1
0172 240 DO 255 J=1,32
0173 DO 255 I=1,32
```

ORIGINAL PAGE IS
OF POOR QUALITY

FORTRAN IV V018-02
CORE=08K, UIC={200,200}

FBI 26-NOV-76 20:19:53 PAGE 004
COLETA, LP:/L1:1=DT1:COLETA.

```
0174 255 P(I,J)=0.0
0175      DO 401 JK=1,DIST
0176      IB=1
0177      JL=CC(2,1)+JK-1
0178      JM=JL+DIST
0179      CALL IRV(5,JL,BUFF(1,IB))
0180      CALL WAIT
0181      DO 400 K=JM,MAK,DIST
0182      CALL IRV(5,K,BUFF(1,NB(IB)))
0183      CALL WAIT
0184      GO TO(300,305,310,315)MODE
0185 300 DO 301 N=NN,IAR
0186      I=IBYTE(N-DIST,BUFF(1,IB))
0187      J=IBYTE(N,BUFF(1,IB))
0188      IF(I.GT.32) I=TABLE(I)
0189      IF(J.GT.32) J=TABLE(J)
0190      P(I,J)=P(I,J)+1.
0191 301 P(J,I)=P(J,I)+1.
0192      GO TO 400
0193 305 DO 302 N=KAR,IAR
0194      I=IBYTE(N,BUFF(1,IB))
0195      J=IBYTE(N,BUFF(1,NB(IB)))
0196      IF(I.GT.32) I=TABLE(I)
0197      IF(J.GT.32) J=TABLE(J)
0198      P(I,J)=P(I,J)+1.
0199 302 P(J,I)=P(J,I)+1.
0200      GO TO 400
0201 310 DO 303 N=NN,IAR
0202      J=IBYTE(N-DIST,BUFF(1,NB(IB)))
0203      I=IBYTE(N,BUFF(1,IB))
0204      IF(I.GT.32) I=TABLE(I)
0205      IF(J.GT.32) J=TABLE(J)
0206      P(I,J)=P(I,J)+1.
0207 303 P(J,I)=P(J,I)+1.
0208      GO TO 400
0209 315 DO 304 N=NN,IAR
0210      I=IBYTE(N-DIST,BUFF(1,IB))
0211      J=IBYTE(N,BUFF(1,NB(IB)))
0212      IF(I.GT.32) I=TABLE(I)
0213      IF(J.GT.32) J=TABLE(J)
0214      P(I,J)=P(I,J)+1.
0215 304 P(J,I)=P(J,I)+1.
0216 400 IB=NB(IB)
0217 401 CONTINUE
0218      WRITE(6,901)MODE
0219 901 FORMAT(1X,'COMPLETA A OBTENCAO DA MATRIZ',I2)
0220      C NORMALIZACAO DAS MATRIZES
0221      DO 405 J=1,32
0222      DO 405 I=1,32
0223 405 P(I,J)=P(I,J)/NORM(MODO)
0224      C OBTENCAO DE CARACTERISTICAS TEXTURAIS A PARTIR DAS MATRIZES
0225 231 CALL FEXT(VW)
0226 232 DO 410 I=1,12
0227 233 GO TO(406,407,408,409)MODO
0228 406 VPW(I)=VW(I)
0229 235 GO TO 410
```

FORTRA IV VOIR-02
CURE=08K, UIC=(200,200)

FRI 26-NOV-75 20:19:53

PAGE 005

COLETA, LP:/LI:1=DT1:COLETA.

```

0236 107 VOW(I)=VW(I)
0237 GO TO 410
0238 408 VRW(I)=VW(I)
0239 GO TO 410
0240 409 VSW(I)=VW(I)
0241 410 CONTINUE
0242 WRITE(6,900)MOD0
0243 900 FORMAT(1X,'FIM DA EXTRACAO DE CARACTERISTICAS DA MATRIZ',I2)
0244 MOD0=MOD0+1
0245 IF(MOD0-4)240,240,420
0246 420 DO 450 I=1,12
0247 FEMED(I)=(VPW(I)+VQW(I)+VRW(I)+VSW(I))/4
0248 Z=FEMED(I)
0249 TAB=(VPW(I)-Z)**2+(VQW(I)-Z)**2+(VRW(I)-Z)**2+(VSW(I)-Z)**2
0250 FEDEP(I)=SQRT(TAB)
0251 AMAX=AMAX1(VPW(I),VQW(I),VRW(I),VSW(I))
0252 AMIN=AMIN1(VPW(I),VQW(I),VRW(I),VSW(I))
0253 450 FERAG(I)=AMAX-AMIN
0254 WRITE(5,500)((FEMED(I),FEDEP(I),FERAG(I)),I=1,12),((XMEDIA(I),
CXVAR(I)),I=1,4),SC,ICLASS)
0255 500 FORMAT(1X,12(3E17.8,/),4(2E17.8,/),5I6.//)
0256 CALL CLOSE(5)
0257 WRITE(3,NREC)((FEMED(I),FEDEP(I),FERAG(I)),I=1,12),((XMEDIA(I),
CXVAR(I)),I=1,4),SC,ICLASS)
0258 GO TO 89
0259 2000 NR0=NR0+1
0260 WRITE(6,404)NR0
0261 404 FORMAT(1X,'TOTAL DE JANELAS PROCESSADAS=',I4)
0262 CALL CLOSE(3)
0263 STOP
0264 END

```


COLETA, LP:/LI:1=DT1:COLETA.

```

0001 SUBROUTINE JANELA(EC, IC, DD, SC, JOB, IDX, IDY)
0002 INTEGER EC(2,2), IC(2,2), DD(2,2), SC(2,2), CURSOR(5)
0003 LOGICAL*1 W(74)
0004 82 CALL OUTPUT(27,12)
0005 WRITE(6,85)EC
0006 85 FORMAT(' EX1=',I6,3X,'EY1=',I6,10X,'EX2=',I6,3X,'EY2=',I6)
0007 WRITE(6,88)IC
0008 88 FORMAT(' IX1=',I6,3X,'IY1=',I6,10X,'IX2=',I6,3X,'IY2=',I6)
0009 WRITE(6,90)
0010 90 FORMAT(/,IX,'ESCOLHA DA JANELA:CR P/ LER COORDENADAS ERTS',/)
0011 NUMB=1
0012 92 CALL OUTPUT(7)
0013 READ(6,20)W
0014 20 FORMAT(74A1)
0015 IF(W(1).EQ."130")GO TO 110
0017 CALL IPK(CURSOR)
0018 DD(1,1)=CURSOR(2)-2*CURSOR(3)-1
0019 DD(1,2)=CURSOR(2)+2*CURSOR(3)
0020 DD(2,1)=CURSOR(4)-2*CURSOR(5)
0021 DD(2,2)=CURSOR(4)+2*CURSOR(5)+1
0022 DO 93 J=1,2
0023 DO 93 K=1,2
0024 93 SC(K,J)=DD(K,J)-IC(K,1)+EC(K,1)
0025 IDX=DD(1,2)-DD(1,1)+1
0026 IDY=DD(2,2)-DD(2,1)+1
0027 NUMB=NUMB+1
0028 IF(NUMB.LE.13)GO TO 95
0030 CALL OUTPUT(27,12)
0031 WRITE(6,85)EC
0032 WRITE(6,88)IC
0033 WRITE(6,90)
0034 NUMB=1
0035 95 WRITE(6,100)SC,IDX,IDY
0036 100 FORMAT(' X1=',I4,2X,'Y1=',I4,3X,'X2=',I4,2X,'Y2=',
C14,2X,'DX=',I3,2X,'DY=',I3)
0037 GO TO 92
0038 110 WRITE(6,115)
0039 115 FORMAT('SSEGUIR,CICLAR OU PARAR?(S/C/P)>',2X)
0040 CALL OUTPUT(7)
0041 READ(6,20)W
0042 CALL FRONT(W,74)
0043 JOB=1
0044 IF(W(1).EQ."103")GO TO 82
0045 IF(W(1).NE."123".AND.W(1).NE."120")GO TO 110
0046 IF(W(1).EQ."120") JOB=0
0050 RETURN
0051 END

```

FORTRAN IV V01B-02 FRI 26-NOV-76 19:11:30 PAGE 001
CORE=08K, UIC=[200,200] SUBROTS,LP:/LI:1=DT1:SUBROTS.

```
0001        SUBROUTINE AUX
0002        COMMON P(32,32),ALFA(32),BETA(64),GAMA(32)
0003        DO 5 I=1,32
0004        ALFA(I)=0.0
0005        DO 5 J=1,32
0006        5        ALFA(I)=ALFA(I)+P(J,I)
0007        RETURN
0008        END
```

FORTRAN IV V01B-02 FRI 26-NOV-76 19:11:54 PAGE 001
CORE=08K, UIC=[200,200] SUBROTS,LP:/LI:1=DT1:SUBROTS.

```
0001        SUBROUTINE ASM(F1)
0002        COMMON P(32,32),ALFA(32),BETA(64),GAMA(32)
0003        F1=0.0
0004        DO 10 I=1,31
0005        F1=F1+P(I,1)*P(I,I)
0006        K=I+1
0007        DO 10 J=K,32
0008        10        F1=F1+2*P(I,J)*P(I,J)
0009        F1=F1+P(32,32)*P(32,32)
0010        RETURN
0011        END
```

FORTRAN IV V01B-02 FRI 26-NOV-76 19:12:18 PAGE 001
CORE=08K, UIC=[200,200] SUBROTS,LP:/LI:1=DT1:SUBROTS.

```
0001        SUBROUTINE AUX1
0002        COMMON P(32,32),ALFA(32),BETA(64),GAMA(32)
0003        DO 35 I=2,33
0004        BETA(I)=0.0
0005        DO 25 M=1,32
0006        N=I-M
0007        IF(N-M)35,30,20
0008        20        BETA(I)=BETA(I)+2*P(M,N)
0009        25        CONTINUE
0010        30        BETA(I)=BETA(I)+P(M,N)
0011        35        CONTINUE
0012        DO 55 I=34,64
0013        BETA(I)=0.0
0014        K=I-32
0015        DO 45 M=K,32
0016        N=I-M
0017        IF(N-M)55,50,40
0018        40        BETA(I)=BETA(I)+2*P(M,N)
0019        45        CONTINUE
0020        50        BETA(I)=BETA(I)+P(M,N)
0021        55        CONTINUE
0022        RETURN
0023        END
```

ORIGINAL PAGE IS
OF POOR QUALITY

FORTRAN IV VO1B-02
CORE=08K, UIC=[200,200]

FRI 26-NOV-76 19:12:46

PAGE 001

SUBROUTS,LP:/LI:1=DT1:SUBROUTS.

```
0001      SUBROUTINE AUX0
0002      COMMON P(32,32),ALFA(32),BETA(64),GAMA(32)
0003      GAMA(1)=0.0
0004      DO 10 M=1,32
0005 10      GAMA(1)=GAMA(1)+P(M,M)
0006      DO 100 K=2,32
0007      L=32-K+1
0008      GAMA(K)=0.0
0009      DO 20 M=1,L
0010 20      GAMA(K)=GAMA(K)+2*P(M,M+K-1)
0011 100      CONTINUE
0012      RETURN
0013      END
```

FORTRAN IV VO1B-02
CORE=08K, UIC=[200,200]

FRI 26-NOV-76 19:13:12

PAGE 001

SUBROUTS,LP:/LI:1=DT1:SUBROUTS.

```
0001      SUBROUTINE COM1(F2)
0002      COMMON P(32,32),ALFA(32),BETA(64),GAMA(32)
0003      F2=0.0
0004      DO 10 M=1,31
0005 10      F2=F2+M*P(M,M+1)
0006      RETURN
0007      END
```

FORTRAN IV VO1B-02
CORE=08K, UIC=[200,200]

FRI 26-NOV-76 19:13:37

PAGE 001

SUBROUTS,LP:/LI:1=DT1:SUBROUTS.

```
0001      SUBROUTINE COR(U,F3)
0002      COMMON P(32,32),ALFA(32),BETA(64),GAMA(32)
0003      U=0.0
0004      V=0.0
0005      W=0.0
0006      DO 20 I=1,32
0007      SOMA=0.0
0008      DO 10 J=1,32
0009 10      SOMA=SOMA+J*P(I,J)
0010      U=U+I*ALFA(I)
0011      V=V+I+I*ALFA(I)
0012 20      W=W+SOMA*I
0013      FOR=U*U
0014      V=V-FOR
0015      F3=(W-FOR)/V
0016      RETURN
0017      END
```

FORTRAN IV V01B-02 FRI 26-NOV-76 19:14:03 PAGE 001
CORE=03K, UIC=[200,200] SUBROUTS,LP:/LI:1=DT1:SUBROUTS.

```
0001      SUBROUTINE VAR(U,F4)
0002      COMMON P(32,32),ALFA(32),BETA(64),GAMA(32)
0003      F4=0.0
0004      DO 10 I=1,32
0005      H=1-U
0006      10      F4=F4+H+H*ALFA(I)
0007      RETURN
0008      END
```

FORTRAN IV V01B-02 FRI 26-NOV-76 19:14:27 PAGE 001
CORE=03K, UIC=[200,200] SUBROUTS,LP:/LI:1=DT1:SUBROUTS.

```
0001      SUBROUTINE XIDM(F5)
0002      COMMON P(32,32),ALFA(32),BETA(64),GAMA(32)
0003      F5=0.0
0004      DO 20 I=1,31
0005      F5=F5+P(I,1)
0006      K=1+1
0007      DO 10 J=K,32
0008      M=1+1
0009      10      F5=F5+2*P(I,J)/(1+M*M)
0010      20      CONTINUE
0011      F5=F5+P(32,32)
0012      RETURN
0013      END
```

FORTRAN IV V01B-02 FRI 26-NOV-76 19:14:53 PAGE 001
CORE=03K, UIC=[200,200] SUBROUTS,LP:/LI:1=DT1:SUBROUTS.

```
0001      SUBROUTINE SUMAVE(F6)
0002      COMMON P(32,32),ALFA(32),BETA(64),GAMA(32)
0003      F6=0.0
0004      DO 20 I=2,64
0005      20      F6=F6+1+BETA(I)
0006      RETURN
0007      END
```

ORIGINAL PAGE IS
OF POOR QUALITY

FORTRAN IV V01B-02 FRI 26-NOV-76 19:15:17 PAGE 001
CORE=04K, UIC=[200,200] SUBROTS,LP:/LI:1=D11:SUBROTS.

```
0001        SUBROUTINE SUMVAR(F6,F7)
0002        COMMON P(32,32),ALFA(32),BETA(64),GAMA(32)
0003        F7=0.0
0004        DO 10 I=2,64
0005        H=1-F6
0006        10 F7=F7+H*H*BETA(I)
0007        RETURN
0008        END
```

FORTRAN IV V01B-02 FRI 26-NOV-76 19:15:40 PAGE 001
CORE=08K, UIC=[200,200] SUBROTS,LP:/LI:1=D11:SUBROTS.

```
0001        SUBROUTINE SUMENT(F8)
0002        COMMON P(32,32),ALFA(32),BETA(64),GAMA(32)
0003        F8=0.0
0004        DO 10 I=2,64
0005        10 F8=F8-BETA(I)+ALOG(BETA(I)+1.0E-7)
0006        RETURN
0007        END
```

FORTRAN IV V01B-02 FRI 26-NOV-76 19:16:03 PAGE 001
CORE=08K, UIC=[200,200] SUBROTS,LP:/LI:1=D11:SUBROTS.

```
0001        SUBROUTINE ENT(F9)
0002        COMMON P(32,32),ALFA(32),BETA(64),GAMA(32)
0003        F9=0.0
0004        DO 20 I=1,31
0005        F9=F9-(P(I,I))*ALOG(P(I,I)+1.0E-7)
0006        K=I+1
0007        DO 10 J=K,32
0008        10 F9=F9-2*(P(I,J))*ALOG(P(I,J)+1.0E-7)
0009        20 CONTINUE
0010        F9=F9-P(32,32)*ALOG(P(32,32)+1.0E-7)
0011        RETURN
0012        END
```

FORTRAN IV VO1B-02 FRI 26-NOV-76 19:16:29 PAGE 001
CORE=08K, UIC=[200,200] SUBROUTS,LP:/LI:1=DT1:SUBROUTS.

```

0001      SUBROUTINE DIFVAR(F10)
0002      COMMON P(32,32),ALFA(32),BETA(64),GAMA(32)
0003      DIFAVE=0.0
0004      DO 10 I=1,31
0005      10      DIFAVE=DIFAVE+I*GAMA(I+1)
0006      F10=0.0
0007      DO 20 J=0,31
0008      H=1-DIFAVE
0009      20      F10=F10+H*H*GAMA(I+1)
0010      RETURN
0011      END

```

FORTRAN IV VO1B-02 FRI 26-NOV-76 19:16:53 PAGE 001
CORE=08K, UIC=[200,200] SUBROUTS,LP:/LI:1=DT1:SUBROUTS.

```

0001      *SUBROUTINE DIFENT(F11)
0002      COMMON P(32,32),ALFA(32),BETA(64),GAMA(32)
0003      F11=0.0
0004      DO 10 I=0,31
0005      W=GAMA(I+1)
0006      10      F11=F11-W+ALOG(W+1.0E-7)
0007      RETURN
0008      END

```

FORTRAN IV VO1B-02 FRI 26-NOV-76 19:17:18 PAGE 001
CORE=08K, UIC=[200,200] SUBROUTS,LP:/LI:1=DT1:SUBROUTS.

```

0001      SUBROUTINE CORME(F9,F12)
0002      COMMON P(32,32),ALFA(32),BETA(64),GAMA(32)
0003      HZ=0.0
0004      HXY1=0.0
0005      DO 20 I=1,32
0006      H=ALFA(I)*ALFA(I)
0007      HZ=HZ-(ALFA(I))*ALOG(ALFA(I)+1.0E-7)
0008      A=ALOG(H+1.0E-7)
0009      HXY1=HXY1-A*P(I,I)
0010      M=I+1
0011      IF(M.GT.32)GOTO 30
0013      DO 20 J=M,32
0014      F=(ALFA(I))*(ALFA(J))
0015      C=ALOG(F+1.0E-7)
0016      20      HXY1=HXY1-2*C*P(I,J)
0017      30      F12=(F9-HXY1)/HZ
0018      RETURN
0019      END

```

ORIGINAL PAGE IS
OF POOR QUALITY

FORTRAN IV V013-02
CORE=08K, UIC={200,200}

FRI 26-NOV-76 19:17:44

PAGE 001

SUBROUTS,LP:/LI:1=DT1:SUBROUTS.

```
0001      SUBROUTINE FEXT(VW)
0002      DIMENSION VW(12)
0003      COMMON P(32,32),ALFA(32),FE1A(64),GAMA(32)
0004      CALL AUX
0005      CALL AUX1
0006      CALL AUX0
0007      CALL ASM(VW(1))
0008      CALL CON1(VW(2))
0009      CALL CUR(U,VW(3))
0010      CALL VAR(U,VW(4))
0011      CALL XIDM(VW(5))
0012      CALL SUBAVE(VW(6))
0013      CALL SUBVAR(VW(6),VW(7))
0014      CALL SUMENT(VW(8))
0015      CALL ENT(VW(9))
0016      CALL DIFVAR(VW(10))
0017      CALL DIFENT(VW(11))
0018      CALL CORME(VW(9),VW(12))
0019      RETURN
0020      • END
```

FORTTRAN IV V018-02
CORE=08K, UJC=(200,200)

FRI 26-NOV-75 20:26:10

PAGE 001

HGRAM-IP:/LJ:1=DT1:HGRAM.

C
C
C
C

PROGRAMA PARA VISUALIZACAO DA CAPACIDADE DE SEPARACAO ENTRE
CLASSES USANDO CARACTERISTICAS TEXTURAIS E/OU ESPECTRAIS

```

0001      INTEGER SC(2,2)
0002      LOGICAL*1 W(74)
0003      DIMENSION X(20,200),LX(200),COUM(50,2),LY(2)
0004      DIMENSION FEAT(44),YMAX(2),ICLA(2)
0005      DATA 1Y/440,0/
0006      CALL OUTPUT(27,12)
0007      WRITE(6,1)
0008 1      FORMAT(13X,'*** SELECAO DE CARACTERISTICAS ***',/)
0009 5      WRITE(6,10)
0010 10     FORMAT('QUANTAS AMOSTRAS EXISTEM?(1-200)>')
0011      CALL OUTPUT(7)
0012      READ(6,20)W
0013 20     FORMAT(74A1)
0014      CALL FRONT(W,74)
0015      IF(W(1).EQ."130") GO TO 2000
0017      L=0
0018      CALL INTFF(L,W,74,NUM)
0019      IF(NUM.LT.1.OR.NUM.GT.200) GO TO 5
0021 25     WRITE(6,30)
0022 30     FORMAT('FAIXA(MAX=20) DE CARACTERISTICAS: INICIAL E FINAL>')
0023      CALL OUTPUT(7)
0024      READ(6,20)W
0025      CALL FRONT(W,74)
0026      IF(W(1).EQ."130") GO TO 2000
0028      L=0
0029      CALL INTFF(L,W,74,MIN)
0030      CALL INTFF(L,W,74,MAX)
0031      IFAX=MAX-MIN+1
0032      IF(MAX.GT.44.OR.MIN.LT.1.OR.MAX.LE.MIN.OR.IFAX.GT.20)GOTO 25
C LEITURA DOS DADOS QUE INTERESSAM NO ARQUIVO TAB.DAT
C DA DECIAPEN#0 CRIADO PELO PROGRAMA 'COLETA'
0034      CALL FDBSET(3,'READONLY')
0035      CALL ASSIGN(3,'DIO:TAB.DAT')
0036      DEFINE FILE 3 (200,100,U,MREC)
0037      MREC=1
0038      DO 39 I=1,NUM
0039      READ(3,MREC)((FEAT(J)),J=1,44),SC,LX(1)
0040      DO 31 L=MIN,MAX
0041      M=L-MIN+1
0042 31     X(M,I)=FEAT(L)
0043 39     CONTINUE
0044      CALL CLOSE(3)
0045 40     WRITE(6,50)
0046 50     FORMAT('QUE CARACTERISTICA NA FAIXA ESCOLHIDA QUER USAR?>')
0047      CALL OUTPUT(7)
0048      READ(6,20)W
0049      CALL FRONT(W,74)
0050      IF(W(1).EQ."130") GO TO 25
0052      L=0
0053      CALL INTFF(L,W,74,IFEAT)
0054      IF(IFEAT.LT.MIN.OR.IFEAT.GT.MAX)GO TO 40
0056      JFEAT=IFEAT-MIN+1

```


FORTRAN IV V01B-02 FPI 20-NOV-76 20:28:10 PAGE 002
CORE=08K, UIC=(200,200) HGRAM,IP:/L1:1=D11:HGRAM.

```

0057 55 WRITE(6,60)
0058 60 FORMAT('SELECÇÃO UM PAR DE CLASSES(1-5)>')
0059 CALL OUTPUT(7)
0060 READ(6,20)W
0061 CALL FRONT(W,74)
0062 IF(W(1).EQ."")GO TO 40
0064 L=0
0065 DO 68 I=1,2
0066 CALL INTFF(L,W,74,ICLA(I))
0067 IF(ICLA(I).GT.5.OR.ICLA(I).LT.1) GO TO 55
0069 68 CONTINUE
C DISCRETIZAÇÃO DAS DISTRIBUIÇÕES E OBTENÇÃO DOS HISTOGRAMAS
0070 DO 100 I=1,NUM
0071 IF(LX(I).NE.ICLA(1).AND.LX(I).NE.ICLA(2))GO TO 100
0073 XMAX=X(JFEAT,I)
0074 XMIN=XMAX
0075 INIC=I+1
0076 GO TO 140
0077 100 CONTINUE
0078 140 DO 200 I=INIC,NUM
0079 IF(LX(I).NE.ICLA(1).AND.LX(I).NE.ICLA(2))GO TO 200
0081 XMAX=AMAX1(X(JFEAT,I),XMAX)
0082 XMIN=AMIN1(X(JFEAT,I),XMIN)
0083 200 CONTINUE
0084 DELTA=(XMAX-XMIN)/48
0085 DO 250 J=1,2
0086 DO 250 I=1,50
0087 250 COUNT(I,J)=0.0
0088 DO 500 I=1,NUM
0089 IF(LX(I).NE.ICLA(1))GO TO 300
0091 J=IFIX((X(JFEAT,I)-XMIN)/DELTA)+1
0092 COUNT(J,1)=COUNT(J,1)+1
0093 GO TO 500
0094 300 IF(LX(I).NE.ICLA(2))GO TO 500
0096 J=IFIX((X(JFEAT,I)-XMIN)/DELTA)+1
0097 COUNT(J,2)=COUNT(J,2)+1
0098 500 CONTINUE
C CONSTRUÇÃO DOS HISTOGRAMAS NO TERMINAL GRAFICO
0099 DO 600 I=1,2
0100 YMAX(I)=0.0
0101 DO 590 J=1,50
0102 590 YMAX(I)=AMAX1(YMAX(I),COUNT(J,I))
0103 600 YMAX(I)=1.1*YMAX(I)
0104 CALL INITT
0105 DO 700 I=1,2
0106 CALL DWINDO(0.,51.,0.0,YMAX(I))
0107 CALL SWINDO(10,1010,IY(I),340)
0108 DO 650 J=1,50
0109 ABC=FLOAT(J)
0110 CALL MOVEA(ABC,0.0)
0111 650 CALL DRAWA(ABC,COUNT(J,1))
0112 CALL MOVEA(0.0,YMAX(I))
0113 CALL DRAWA(0.0,0.0)
0114 CALL DRAWA(51.,0.0)
0115 700 CONTINUE
0116 CALL MUVAHS(0,430)

```

FORTRAN IV VO18-02
CORE=08K, LIC=(200,200)

FRI 26-NOV-76 20:26:10

PAGE 003

HGRAM,LP:/LI:1=DT1:HGRAM.

```
0117      CALL ANMODE
0118      WRITE(6,800) 1FEAT,ICLA
0119      300      FORMAT(IX,'CAFACTERISTICA USADA:',13,5X,'CLASSES ',11,
                 C' E ',11)
0120      READ(6,20)*
0121      CALL OUTPUT(27,12)
0122      GO TO 55
0123      2000      STOP
0124      END
```

Cada janela foi equalizada em 32 níveis e colocada no canal 5 do sistema I-100, de onde eram extraídas as respectivas matrizes. Como foi visto no Capítulo III, cada tipo de textura fornece um conjunto de 3 características, que são a média, o desvio padrão e a faixa de variação dos valores dessa medida, para as quatro matrizes de coocorrência. Tem-se, então, um total de 36 medidas de textura, as quais serão denominadas pelo tipo de medida seguido da letra M, D ou F, caso se trate, respectivamente, da média, do desvio padrão ou da faixa de variação.

Além dessas 36 medidas de textura, foram, também, computadas 8 medidas espectrais: média e variância dos níveis de cinza dos pontos da janela, para cada um dos 4 canais, perfazendo um total de 44 características para cada janela. O tempo total de processamento, de cada janela, foi por volta de 40 segundos.

Na fase de classificação, o conjunto das 182 janelas foi dividido em duas partes iguais: uma para treinamento do classificador e outra para teste. Portanto, o número máximo de acertos nas Tabelas, que serão mostradas mais adiante é 91.

4.3 - RESULTADOS

Inicialmente foram realizadas classificações, utilizando cada uma das 44 características individualmente. A Tabela IV.1 mostra os resultados obtidos, com o uso do Mín-máx e do vizinho mais próximo (VMP). Nesta Tabela, as características espectrais são designadas pelo número da banda correspondente (4-7), junto com a letra M, no caso de ser média, ou V, se for variância.

É difícil fazer uma análise baseada apenas nos resultados de classificações, usando características individuais. É, porém, impraticável se fazer todas as combinações possíveis de características, para analisar, em bases sólidas, a importância de cada uma delas. Num processo natural e empírico de escolha, pode-se selecionar aquelas que deram melhores resultados individualmente, desprezando-se as demais. Ou então, procura-se uma segunda característica que, junto com a melhor delas, indivi

FORTRAN IV V018-02
CURE=08K, UIC={200,200}

FRI 26-NOV-76 20:26:10

PAGE 001

CATEG,LP:/L1:1=DT1:CATEG.

```

C
C
C PROGRAMA PARA CLASSIFICACAO DE AMOSTRAS
C PODEM SER USADOS 2 METODOS: O MIN-MAX E O DO VIZINHO MAIS PROXIMO
C CONJUNTO DE TREINO EH CONSTITUIDO DAS AMOSTRAS IMPARES
C CONJUNTO DE TESTE EH CONSTITUIDO DAS AMOSTRAS PARES
C
C
0001 LOGICAL*1 W(74)
0002 DIMENSION IX(2,2),JCOMP(20),INIC(5),LX(200),A(20,5)
0003 DIMENSION B(20,5),Y(20),FEAT(44),X(20,200),I101(3)
0004 CALL OUTPUT(27,12)
0005 1 WRITE(6,2)
0006 2 FORMAT(13X,'*** CLASSIFICADOR ***',//,' TOTAL DE',
C' AMOSTRAS(1-200) E DIMENSAO DO ESPACO(1-20)?',//,'s>')
0007 CALL OUTPUT(7)
0008 READ(6,5)W
0009 5 FORMAT(74A1)
0010 CALL FRONT(W,74)
0011 IF(W(1).EQ."130")GO TO 2000
0012 L=0
0013 CALL INTFF(L,W,74,NUMB)
0014 CALL INTFF(L,W,74,JDIM)
0015 IF(NUMB.LE.1.OR.NUMB.GT.200.OR.JDIM.GT.20.OR.JDIM.LT.1)GO TO 1
0016 13 WRITE(6,15)JDIM
0017 15 FORMAT(1X,'O-TRE COM AS ',I2,' CARACTERISTICAS QUE VAI USAR:',
C//,'S>')
0020 CALL OUTPUT(7)
0021 READ(6,5)W
0022 CALL FRONT(W,74)
0023 IF(W(1).EQ."130")GO TO 2000
0024 L=0
0025 DO 20 I=1,JDIM
0026 CALL INTFF(L,W,74,JCOMP(I))
0027 IF(JCOMP(I).EQ.0.OR.JCOMP(I).GT.44)GO TO 13
0028 20 CONTINUE
0029 21 WRITE(6,22)
0030 22 FORMAT('QUANTAS CLASSES EXISTEM?(2-5)>')
0031 CALL OUTPUT(7)
0032 READ(6,5)W
0033 CALL FRONT(W,74)
0034 IF(W(1).EQ."130")GO TO 2000
0035 L=0
0036 CALL INTFF(L,W,74,KCLA)
0037 IF(KCLA.LE.1.OR.KCLA.GT.5)GO TO 21
C LEITURA DE DADOS E MONTAGEM DA MATRIZ DE AMOSTRAS
0042 CALL FDBSEI(3,'READONLY')
0043 CALL ASSIGN(3,'DRG:TAB.DAT')
0044 DEFINE FILE 3 (200,100,U,NREC)
0045 NREC=1
0046 DO 100 I=1,NUMB
0047 READ(3,NREC)((FEAT(J)),J=1,44),IX,LX(1)
0048 DO 30 J=1,JDIM
0049 K=JCOMP(J)
0050 30 X(J,1)=FEAT(K)
0051 100 CONTINUE

```

FORTRAN IV V01B-02
CORE=08K, UIC=(200,200).

FRI 26-NOV-76 20:26:10

PAGE 002

CATEG,LP:/LI:1=DF1:CATEG.

```

0052      CALL CLOSE(3)
      C NORMALIZACAO DOS FEATURES CENTRO DE CADA COMPONENTE
0053      DO 2100 I=1,JDIM
0054          XMAX=X(1,1)
0055          XMIN=XMAX
0056      DO 2050 J=2,NUMB
0057          XMAX=AMAX1(XMAX,X(I,J))
0058      2050  XMIN=AMIN1(XMIN,X(I,J))
0059      DO 2080 J=1,NUMB
0060      2080  X(I,J)=(X(I,J)-XMIN)/(XMAX-XMIN)
0061      2100  CONTINUE
0062      104  WRITE(6,105)
0063      105  FORMAT('SOUER USAR O (M)INMAX OU O (V)IZINHO MAIS PROXIMO?')
0064      CALL OUTPUT(7)
0065      READ(6,5)W
0066      CALL FRONT(W,74)
0067      IF(W(1).EQ."130")GO TO 2000
0069      IF(W(1).EQ."126")GO TO 530
0071      IF(W(1).NE."115")GO TO 104

      C
      C CLASSIFICACAO COM O METODO MINMAX
      C
0073      DO 110 I=1,KCLA
0074      110  INIC(I)=0
0075      DO 200 I=1,NUMB,2
0076          J=LX(I)
0077          IF(INIC(J).EQ.1)GO TO 200
0079      DO 150 M=1,JDIM
0080          A(M,J)=X(M,I)
0081      150  B(M,J)=X(M,I)
0082          INIC(J)=1
0083      DO 170 N=1,KCLA
0084          IF(INIC(N).NE.1)GO TO 200
0086      170  CONTINUE
0087          GO TO-250
0088      250  CONTINUE
0089          WRITE(6,210)
0090      210  FORMAT(1X,'ENGANO-NAO EXISTEM TANTAS CLASSES!')
0091          GO TO 21
      C DETERMINACAO DO PARALELEPIPEDO CORRESPONDENTE A CADA
      C CLASSE USANDO O CONJUNTO DE TREINO(AMOSTRAS IMPARES)
0092      250  DO 220 M=1,KCLA
0093      220  INIC(M)=0
0094      DO 400 I=1,NUMB,2
0095          N=LX(I)
0096          INIC(N)=INIC(M)+1
0097      DO 230 M=1,JDIM
0098          A(M,N)=AMAX1(A(M,N),X(M,I))
0099      230  B(M,N)=AMIN1(B(M,N),X(M,I))
0100      400  CONTINUE
0101      DO 430 J=1,KCLA
0102          DO 430 M=1,JDIM
0103          TETA=(A(M,J)-B(M,J))/(INIC(J)-1)
0104          A(M,J)=A(M,J)+TETA
0105      430  B(M,J)=B(M,J)-TETA
0106          DO 440 MOD=1,3

```

FORTRAN IV V01B-02
CORE=08K, UIC=(200,200)

FRI 26-NOV-75 20:26:10

PAGE 003

CATEG,LP:/LI:1=DT1:CATEG.

```

0107 440 ITOT(MOD)=0
      C TESTE DE CADA UMA DAS AMOSTRAS PARES
0108      IAM=0
0109      IERR=0
0110      IOK=0
0111      IER=0
0112      DO 500 I=2,NUMB,2
0113      IAM=IAM+1
0114      DO 470 J=1,JDIM
0115 470 Y(J)=X(J,I)
0116      CALL TESTA(JDIM,KCLA,A,B,Y,ICAT,MOD)
-0117      ITOT(MOD)=ITOT(MOD)+1
      C COMPARA A CATEGORIA ICAT ATRIBUIDA PELO CLASSIFICADOR COM
      C A CATEGORIA VERDADEIRA QUE ESTA CONTEIDA NO VETOR LX
0118      IF(JCAT.EQ.LX(1))GO TO 480
0120      IOK=IOK+1
0121      GO TO 500
0122 480 IERR=IERR+1
0123      IF(MOD.EQ.3)IER=IER+1
0125      WRITE(6,490)LX(1),ICAT
0126 490 FORMAT(1X,'AMOSTRA DA CATEGORIA:',12,' CLASSIFICADA COMO CA'
      C, 'ATEGORIA:',13)
0127 500 CONTINUE
0128      PERCEN=IOK*100.0/IAM
0129      WRITE(6,510)PERCEN
0130 510 FORMAT(1X,'PERCENTAGEM DE CLASSIFICACAO CORRETA:',F5.2)
0131      NTESTE=NUMB-IAM
0132      CALL ASSIGN(5,'LP:')
0133      WRITE(5,520)(NTESTE,IAM)
0134 520 FORMAT(///,10X,'*** RESULTADO DA CLASSIFICACAO-MINMAX ***',/
      C3X,'AMOSTRAS PARA TREINO:',13,5X,'AMOSTRAS TESTADAS:',13)
0135      WRITE(5,521)(JDIM,IERR,((JCOMP(J)),J=1,JDIM))
0136 521 FORMAT(1X,'DIMENSAO DO ESPACO:',13,10X,'TOTAL DE',
      C' ERROS:',13,/, ' CARACTERISTICAS:',12I3,/,17X,8I3)
0137      WRITE(5,522)PERCEN
0138 522 FORMAT(5X,'PERCENTAGEM DE CLASSIFICACAO CORRETA:',F5.2,'%')
0139      WRITE(5,525)ITOT,IER
0140 525 FORMAT(14,1X,,'CAIRAM NOS LIMITES DE APENAS UMA CLASSE',/,
      C14,1X,'CAIRAM NOS LIMITES DE MAIS DE UMA CLASSE',/,14,
      C1X,'NAO CAIRAM DENTRO DOS LIMITES DE ALGUMA CLASSE',
      C/,14,1X,'DESIAS ULTIMAS RESULTAFAM EM ERRO ')
0141      CALL CLOSE(5)
0142      GO TO 104

      C
      C CLASSIFICACAO BASEADA NA CATEGORIA DO VIZINHO MAIS PROXIMO
      C
0143 530 NTESTE=0
0144      IOK=0
0145      IERR=0
0146      DO 900 I=2,NUMB,2
0147      NTESTE=NTESTE+1
0148      DO 790 J=1,NUMB,2
0149      PRNM=0.0
0150      DO 780 K=1,JDIM
0151      T=X(K,I)-X(K,J)
0152      T=ABS(T)

```

FORTRAN IV VOIS-02
CORE=J8K, DIC=[200,200]

FRI 26-NOV-76 20:26:10

PAGE 004

CATEG,LP:/LI:1=DT1:CATEG.

```
0153 780 PRBM=PRBM+1*I
0154      IF(J.EQ.1)SELI=PRBM
0156      SELI=AMIN1(PRBM,SELI)
0157      IF(SELI.EQ.PRBM)INDEX=J
0159 790 CONTINUE
0160      ICAT=LX(INDEX)
      C COMPARA A CATEGORIA ICAT ATRIBUIDA PELO CLASSIFICADOR COM
      C A CATEGORIA VERDADEIRA QUE ESTA CONTIDA NO VETOR LX
0161      IF(ICAT.NE.LX(1))GO TO 880
0163      IOK=IOK+1
0164      GO TO 900
0165 880 IERR=IERR+1
0166      WRITE(6,490)(LX(I),ICAT)
0167 900 CONTINUE
0168      IAM=NUMB-NTESTE
0169      PERCEN=IOK*100.0/IAM
0170      WRITE(6,510)PERCEN
0171      CALL ASSIGN(5,'LP:')
0172      WRITE(5,910)(NTESTE,IAM)
0173 910 FORMAT(///,2X,'*** RESULTADO DA CLASSIFICACAO-VIZINHO MAIS'
      C,' PROXIMO ***',/,3X,'APOSTAS PARA DEIXO: ',13,5X,'AMUS'
      C,' IRAS TESTADAS: ',13)
0174      WRITE(5,521)(JDIM,IERR,((JCOMP(J)),J=1,JDIM))
0175      WRITE(5,522)PERCEN
0176      CALL CLOSE(5)
0177      GO TO 104
0178 2000 STOP
0179      END
```

FORTRAN IV V018-02 FR-1 26-NOV-76 20:26:10 PAGE 001
CORE=08K, UIC=[200,200] CATEG,LP:/LI:1=DT1:CATEG.

```
0001      SUBROUTINE TESTA(JDIM,KCLA,A,B,Y,ICAT,MOD)
0002      DIMENSION A(20,5),B(20,5),Y(20),PRB(5),LIM(5)
0003      NO=0
0004      DO 15 I=1,KCLA
0005      LIM(I)=0
0006      DO 5 J=1,JDIM
0007      IF(Y(J).LT.B(J,I).OR.Y(J).GT.A(J,I))GO TO 15
0009 5      CONTINUE
0010      LIM(I)=1
0011      NO=NO+1
0012 15     CONTINUE
0013      IF(NO.EQ.0)GO TO 500
0015      IF(NO.GT.1)GO TO 300
0017      DO 30 I=1,KCLA
0018      IF(LIM(I).EQ.1)GO TO 40
0020 30     CONTINUE
0021 40     ICAT=1
0022      MOD=1
0023      RETURN
0024 300     PRB=0.0
0025      DO 350 I=1,KCLA
0026      IF(LIM(I).NE.1)GO TO 350
0028      PRB(I)=1.0
0029      DO 330 J=1,JDIM
0030 330     PRB(I)=PRB(I)/(A(J,I)-B(J,I))
0031      PRB(I)=1/(PRB(I)+PRB(I))
0032 350     CONTINUE
0033      DO 360 I=1,KCLA
0034      IF(LIM(I).NE.1)GO TO 360
0036      IF(PRB(I).EQ.PRBM)GO TO 380
0038 360     CONTINUE
0039 380     ICAT=1
0040      MOD=2
0041      RETURN
0042 500     PRB=0.0
0043      DO 600 J=1,KCLA
0044      PRB(J)=0.0
0045      DO 550 I=1,JDIM
0046      IF(Y(I).GT.B(I,J).OR.Y(I).LT.A(I,J))GO TO 550
0048      TETA=Y(I)-B(I,J)
0049      TETA=ABS(TETA)
0050      VETA=Y(I)-A(I,J)
0051      VETA=ABS(VETA)
0052      TETA=AMIN1(VETA,TETA)
0053      PRB(J)=B(J)+TETA*TETA
0054 550     CONTINUE
0055      IF(.EQ.1)PRB=PRB(I)
0057 600     PRB=AMIN1(PRBM,PRB(J))
0058      DO 710 J=1,KCLA
0059      IF(PRBM.EQ.PRB(J))GO TO 720
0061 710     CONTINUE
0062 720     ICAT=J
0063      MOD=3
0064      RETURN
0065      END
```